

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE M'HAMED BOUGARA-BOUMERDES



Faculté de Technologie

Département Ingénierie des Systèmes Electriques

Mémoire de Master

Présenté par

CHAOUCHE Lilia

Filière : Electronique

Spécialité : Electronique des Systèmes Embarqués

**Etude d'un système de maintenance prédictive à
base d'Iot avec apprentissage automatique**

Soutenu le 01/07 /2024 devant le jury composé de :

YAKHELEF	Yassine	MCA	UMBB	Président
HAROUNE	Radia	MAA	UMBB	Examinatrice
RAHMOUNE	Fayçal	Prof	UMBB	Encadreur

2023/2024

Dédicaces

À MES PARENTS, source inépuisable d'amour, de soutien et de sacrifice, En cette occasion spéciale, je tiens à vous dédier ce travail avec une profonde gratitude et un amour sincère. Votre présence constante dans ma vie, vos encouragements inébranlables et votre soutien inconditionnel ont été les piliers sur lesquels j'ai pu construire mes réalisations.

À mes chers frères, Lounes, Rachid et Aghiles, pour être là à mes côtés.

À mes chères sœurs, Ferial, Sadia, et Lydia. A mes tantes HAKIMA et MALIKA

À mes chères grand-père

À ma chère grand-mère, « Yema Hebbou », à qui je souhaite une bonne santé et longue vie.

*À mon mari adoré “ **Abdel Wahab** “, pour son amour, son soutien et sa patience. Tu es ma source de force et d'inspiration.*

À Mr BELAICHIA Mahmoud, pour son soutien et ses encouragements précieux qui m'ont aidé à surmonter les défis et à persévérer.

À tous mes oncles de la famille BELHAMRI

À mes chères amies : Hayet, Manel, Salima, Khaoula, Halima ...

À toute ma famille, et ma Belle famille

À tous ceux que j'aime et ceux qui m'aiment.

CHAOUCHE LILIA

Remerciement

Au nom d'Allah, Le Clément, Le Miséricordieux, je rends tout d'abord grâce à Allah le Tout-Puissant de m'avoir doté du savoir, de la santé et de la volonté d'apprendre.

Ce modeste travail, fruit de mon cursus, n'a été possible que grâce au concours de mes enseignants, dont je loue les efforts qu'ils ont consentis durant toutes ces années.

Je souhaite adresser mes plus sincères remerciements aux personnes qui ont cru en moi et qui m'ont permis d'arriver au bout de ce travail.

*Je tiens à remercier chaleureusement mon promoteur, Monsieur **RAHMOUNE Fayçal**, pour son assistance, ses conseils, sa disponibilité, et surtout pour son précieuse contribution à l'aboutissement de mes efforts.*

Je remercie cordialement les membres du jury pour l'honneur qu'ils me font en examinant mon travail.

Enfin, mes vifs et sincères remerciements vont à tous ceux qui, de près ou de loin, ont contribué par leurs conseils, leurs encouragements et leur amitié, à l'édification de ce mémoire

ملخص

يتناول هذا البحث دراسة نظام الصيانة التنبؤية المعتمد على إنترنت الأشياء، والتعلم الآلي، باستخدام نماذج الشبكات العصبية الاصطناعية والانحدار اللوجستي. تهدف الصيانة التنبؤية إلى التنبؤ بالأعطال المحتملة للأجهزة قبل حدوثها، مما يقلل من تكاليف الصيانة وفترات التوقف. يتيح تكامل أجهزة الاستشعار الخاصة بإنترنت الأشياء جمع البيانات في الوقت الفعلي، بينما تقوم خوارزميات التعلم الآلي بتحليل هذه البيانات للتنبؤ بالأعطال المحتملة. تظهر نتائج هذه الدراسة أن نماذج الشبكات العصبية الاصطناعية والانحدار اللوجستي يمكنها تقديم تنبؤات دقيقة وموثوقة، مما يساهم في تحسين إدارة المعدات الصناعية.

Abstract

This thesis focuses on the study of a predictive maintenance system based on the Internet of Things (IoT) and machine learning, using Artificial Neural Networks (ANN) and Logistic Regression models. Predictive maintenance aims to anticipate equipment failures before they occur, thereby reducing maintenance costs and downtime. The integration of IoT sensors enables real-time data collection, while machine learning algorithms analyze this data to predict potential failures. The results of this study show that ANN and Logistic Regression models can provide accurate and reliable predictions, contributing to better management of industrial equipment.

Resumé

Ce mémoire porte sur l'étude d'un système de maintenance prédictive basé sur l'Internet des Objets (IoT) et l'apprentissage automatique, en utilisant des modèles de Réseaux de Neurones Artificiels (ANN) et de Régression Logistique. La maintenance prédictive vise à anticiper les défaillances des équipements avant qu'elles ne se produisent, réduisant ainsi les coûts de maintenance et les temps d'arrêt. L'intégration de capteurs IoT permet de collecter des données en temps réel, tandis que les algorithmes d'apprentissage automatique analysent ces données pour prévoir les pannes potentielles. Les résultats de cette étude montrent que les modèles ANN et de Régression Logistique peuvent fournir des prédictions précises et fiables, contribuant à une meilleure gestion des équipements industriels.

Table des matières

Dédicaces	ii
Remerciement.....	iii
ملخص.....	iv
Abstract	iv
Resumé.....	iv

INTRODUCTION GENERALE

I. CHAPITRE 1 : Généralité sur la maintenance prédictive à base d'Iot

I.1 Introduction	5
I.2 La maintenance	5
I.2.1 Pourquoi entretenir les machines ?	6
I.3 Type de Maintenance	6
I.3.1 Maintenance Réactive (RM) :	6
I.3.1.1 Avantages de la RM.....	6
I.3.1.2 Ecueils de la RM.....	7
I.3.2 Maintenance corrective (CM) :	7
I.3.2.1 Avantages de la Maintenance Corrective	8
I.3.2.2 Ecueils de la Maintenance Corrective.....	8
I.3.3 Maintenance Prédictive (Pdm)	8
I.3.3.1 Avantages de la Maintenance Prédictive (PdM).....	8

I.3.3.2 Ecueils de la Maintenance Prédicative (PdM) :.....	9
I.3.4 Maintenance Proactive et Autonome :.....	9
I.4 Industrie 4.0.....	10
I.4.1 Avantages et inconvénients :.....	11
a) Avantages :.....	11
b) Inconvénients :.....	12
I.4.2 Technologies clés de l'industrie 4.0	12
I.4.2.1 IoT.....	12
I.4.2.2 BIG Data :.....	13
I.4.3 Intelligence Artificielle (IA) et Machine Learning (ML)	13
I.4.4 Intégration de l'IoT dans la maintenance prédictive	14
I.5 Types de Défauts sur les Équipement	16
I.5.1 Défauts Mécaniques :.....	16
I.5.2 Défauts Électriques :.....	16
I.5.3 Défauts Thermiques :.....	16
I.5.4 Défauts Hydrauliques :	16
I.5.5 Défauts de Lubrification :	17
I.5.6 Défauts Environnementaux :.....	17
I.5.7 Défauts de Contrôle et de Communication :.....	17
I.6 Conclusion.....	18

II. CHAPITRE 2: Méthodes d'apprentissage automatique et internet des objets connectés

II.1 Introduction.....	20
II.2 L'apprentissage automatique	20
II.2.1 Méthodes d'apprentissage automatique	21
II.2.1.1 L'apprentissage supervisé :	22
II.2.1.1.1 Classification	23
II.2.1.1.2 Régression	24
II.2.1.2 L'apprentissage non supervisé	24
II.3 Régression logistique	25
II.4 Réseaux de neurones artificiels.....	25
II.4.1 Structure	26
II.4.2 Principe de fonctionnement d'algorithme	27
II.5 L'internet des objets.....	28
II.5.1 Définition.....	28
II.5.2 Fonctionnement de l'IoT dans la Maintenance Prédicative.....	29
II.5.3 L'importance d'IoT	30
II.6 Conclusion	31

III. CHAPITRE 3 : Mise en œuvre de la méthode et résultats de simulation

III.1 Introduction	33
III.2 Environnement de Développement	33
III.2.1 Google collab	33
III.2.2 Visual Studio Code	34
III.2.3 Python	34
III.2.4 Pandas :	35
III.2.5 Keras :	35
III.2.6 TensorFlow	36
III.3 Phase d'apprentissage	37
III.3.1 Dataset.....	37
III.3.1.1 Structure du Dataset	37
III.3.1.2 Variables Principales	37
III.3.1.3 Exemples de Variables de Capteurs	37
III.4 Évaluation des modèles	38
III.4.1 Taux d'apprentissage (Accuracy)	38
III.4.2 Matrice de confusion	38
III.4.3 Recal et la précision :	39
III.4.4 F1 score	39
III.5 Résultats de simulation	40
III.5.1 Paramètres d'évaluation de Régression logistique.....	40

III.5.2 Paramètres d'évaluation de ANN	42
III.6 Conclusion	47
Références	52

Listes Des Figures

Figure I_1 convolution de l'industrie [6]-----	11
Figure I_2 Organisation des composants de l'Intelligence Artificielle [8] -----	14
Figure II_1 Le fonctionnement général d'apprentissage automatique [10] -----	21
Figure II_2 Méthodes d'apprentissage automatique-----	21
Figure II_3 Fonctionnement de l'apprentissage supervisé pour un problème de classification. -----	22
Figure II_4 Phase d'apprentissage du modèle d'apprentissage supervisé. -----	23
Figure II_5 Le regroupement identifie des modèles cachés dans vos données. -----	24
Figure II_6 Réseaux de neurones artificiels [16]. -----	26
Figure II_7 Diagramme de ANN-----	27
Figure III_1 fenetre de google collab-----	33
Figure III.2 Visual Studio Code -----	34
Figure III.5 logo de python-----	35
Figure III.3 logo de Pandas [28]-----	35
Figure III.4 Logo de Keras -----	36
Figure III.5 TensorFlow -----	37
Figure III.6 Matrice de confusion -----	39
Tableau III_1 précision, Recall et score F1 en utilisant la régression logistique-----	40
Figure III_7 matrices de confusion LR-----	40
Figure III_8 Scores de Précision, Rappel et F1 par Classe -----	41
Figure III_9 courbe d'apprentissage RL -----	41
Tableau III_2 précision, Recall et score F1 en utilisant le modèle ANN-----	42
Figure III_10 Scores de Précision, Rappel et F1 par Classe -----	42
-----	43

Figure III_11 Matrice de confusion pour ANN -----	43
Figure III_12 courbes d'apprentissage pour ANN-----	43
Figure III_13 Architecture de ANN -----	45
Figure III.14 L'organigramme de fonctionnement de ANN -----	46

Liste de Tableaux

Tableau III_1 précision, Recall et score F1 en utilisant la régression logistique -----40

Tableau III_2 précision, Recall et score F1 en utilisant le modèle ANN -----42

Abréviation

ANN	Artificial <i>Neural Network</i>
CM	Confusion Matrice
CM	Corrective Maintenance
DP	Deep Learning
FN	False Negative
FP	False Positive
IA	Intelligence Artificiel
ID	IDentifiant
IOT	Internet Of Things
ML	Machine Learning
PdM	Predictive Maintenance
ReLU	Rectified Linear Unit
RFID	Radio Frequency Identification
RL	Régression Logistique
RM	Réactive Maintenance
RNA	Réseaux de Neurone Artificial
TN	True Negative
TP	True Positive

INTRODUCTION GENERALE

INTRODUCTION GENERALE

La maintenance prédictive est une stratégie de maintenance avancée qui utilise les technologies de l'Internet des objets (IoT) et l'apprentissage automatique pour surveiller l'état des équipements et prédire les pannes potentielles avant qu'elles ne se produisent. [1]

L'utilisation croissante des technologies de l'Internet des objets (IoT) et de l'apprentissage automatique a ouvert la voie à des avancées significatives dans divers domaines, dont la maintenance prédictive. Cette approche innovante permet de prévoir les pannes potentielles des équipements avant qu'elles ne surviennent, réduisant ainsi les coûts de maintenance et augmentant la durée de vie des machines. La maintenance prédictive est particulièrement cruciale dans les industries où la fiabilité des équipements est primordiale pour la sécurité et l'efficacité opérationnelle.

Le développement d'un système de maintenance prédictive présente plusieurs défis techniques et opérationnels, notamment la collecte et l'analyse en temps réel des données provenant de différents capteurs IoT. Les algorithmes d'apprentissage automatique jouent un rôle clé dans ce contexte, permettant de traiter de grandes quantités de données et d'identifier des schémas indicatifs de pannes imminentes. En intégrant ces technologies, il est possible de surveiller en continu l'état des équipements et d'intervenir de manière proactive.

Notre projet de fin d'études s'inscrit dans ce contexte avec pour objectif la conception et le développement d'un système de maintenance prédictive basé sur l'IoT et l'apprentissage automatique. En optant pour une approche multi-technologique, nous tenons compte de la diversité des environnements industriels et des types d'équipements. Chaque technologie de détection présente ses propres avantages et inconvénients, et certaines peuvent être plus efficaces que d'autres dans des contextes spécifiques. En intégrant plusieurs technologies, nous augmentons nos chances de détecter et de prévoir les pannes, quel que soit l'environnement dans lequel les équipements évoluent. De plus, cela nous permet de tirer parti des progrès technologiques réalisés dans chaque domaine et de renforcer la performance globale de notre solution.

Dans ce travail, nous allons explorer les différentes approches de détection et de prédiction des pannes, en nous concentrant sur les technologies les plus prometteuses pour réaliser une plateforme multi-capteurs pour la maintenance prédictive.

INTRODUCTION GENERALE

Enfin, nous évaluerons les performances de notre système de maintenance prédictive en utilisant les méthodes de performances.

Ce mémoire est organisé en trois chapitres, chacun traitant d'un contenu spécifique, résumé brièvement comme suit :

Chapitre 1 : Généralité sur la maintenance prédictive à base d'Iot

Chapitre 2 : Méthode d'apprentissage automatique et Iot

Chapitre 3 : Mise en œuvre de la méthode et résultats de simulation

Ce mémoire vise à démontrer l'efficacité d'un système de maintenance prédictive basé sur l'IoT et l'apprentissage automatique, apportant ainsi une contribution significative à l'optimisation des processus de maintenance et à la réduction des coûts opérationnels, tout en augmentant la durée de vie et la fiabilité des équipements industriels.

I. CHAPITRE 1

Généralité sur la maintenance prédictive à base d'Iot

I.1 Introduction

L'avènement rapide des technologies de l'information et de la communication a entraîné une révolution dans le secteur industriel. L'émergence de l'Internet des Objets (IoT), des Big Data et de l'Intelligence Artificielle a conduit à une convergence sans précédent des mondes physique et virtuel, marquant ainsi le début de l'ère de l'Industrie 4.0.

Dans cette ère de transformation, les entreprises sont confrontées à des changements majeurs, notamment dans le domaine de la maintenance. Autrefois perçue comme une fonction réactive, la maintenance subit une profonde transformation pour devenir proactive et prédictive. Cette évolution est rendue possible grâce à l'utilisation intelligente des technologies de l'Industrie 4.0, permettant ainsi d'anticiper et de prévenir les pannes avant qu'elles ne surviennent.

Dans ce chapitre on vise à fournir une vue d'ensemble des principes fondamentaux de la maintenance prédictive à base d'IoT avec apprentissages automatique.

I.2 La maintenance

La Maintenance, peut être généralement défini comme les actions ou les mesures prises pour maintenir ou améliorer l'état et les performances d'une machine.

Pour bien comprendre les différentes étapes de la maintenance, nous devons en définir quelques-unes :

- **Symptôme** : écart anormal d'une quantité observable
- **Défaut** : il s'agit de la déviation anormale d'au moins une caractéristique d'un composant ou un système.
- **Défaillance** : c'est lorsqu'un composant ou un système s'arrête définitivement remplir sa fonction. Défaillance partielle : détérioration de la capacité d'un système pour exécuter la fonction requise.
- **Défaillance complète** : arrêt de la capacité d'un système à effectuer la fonction requise [2].

I.2.1 Pourquoi entretenir les machines ?

- Prévention des défaillances et des pannes

L'entretien régulier des machines est crucial pour réduire les risques de défaillance. En assurant que toutes les pièces restent en bon état et opérationnelles, les pannes peuvent être identifiées et traitées avant qu'elles ne surviennent pendant la production. Cela permet d'éviter des temps d'arrêt imprévus, des remplacements de pièces coûteux, des factures de réparation élevées et une baisse de la productivité.

- Fonctionnement efficace des machines

Il est essentiel de maintenir les machines en bon état de fonctionnement pour garantir leur efficacité et leur fluidité. Un bon entretien conduit à une productivité élevée, permettant à l'entreprise de répondre efficacement à la demande du marché. De plus, des machines fiables augmentent la stabilité de l'usine, ce qui se traduit par des bénéfices plus élevés pour l'entreprise.

- Prévention des blessures

Les machines non entretenues peuvent représenter un danger pour les opérateurs, car leur fonctionnement n'est pas optimal et leur comportement peut devenir imprévisible. Un entretien régulier permet de s'assurer que les machines fonctionnent correctement et en toute sécurité, réduisant ainsi les risques d'accidents et de blessures sur le lieu de travail.

I.3 Type de Maintenance

I.3.1 Maintenance Réactive (RM) :

À ses débuts, la maintenance industrielle était principalement réactive, c'est-à-dire qu'elle intervenait uniquement après qu'un équipement avait subi une panne ou un dysfonctionnement. Les réparations étaient effectuées de manière ad hoc, souvent en urgence, ce qui entraînait des temps d'arrêt coûteux et imprévus pour les entreprises.[5]

I.3.1.1 Avantages de la RM

- Pas de coût initial : Aucun coût initial, car la machine n'est réparée qu'après une panne.
- Aucune planification nécessaire : Les techniciens réparent l'équipement lorsqu'il tombe en panne. Comme les pannes sont imprévisibles, aucun temps n'est consacré à la planification des réparations.

I.3.1.2 Ecueils de la RM

- Coûts plus élevés : Les défaillances inattendues peuvent s'avérer coûteuses en raison des commandes tardives pour le remplacement des pièces, ce qui peut entraîner une réputation endommagée et un impact sur les revenus
- Problèmes de sécurité : Les machines laissées à fonctionner jusqu'à la défaillance peuvent présenter un risque pour les opérateurs, car leur comportement ne peut être prédit.
- Utilisation inefficace du temps : La maintenance réactive surprend souvent les propriétaires de machines et peut être chronophage, car ils doivent rassembler les informations nécessaires pour la réparation, ce qui peut inclure la recherche de personnel ayant l'expertise requise et la commande des pièces à remplacer.
- Problèmes d'accumulation : Lorsque les tâches de maintenance s'accumulent, cela peut entraîner un retard de maintenance difficile à résoudre.
- Coûts énergétiques plus élevés : Le fait de ne pas entretenir les machines entraîne généralement une utilisation accrue de l'énergie, car une grande partie de l'énergie est perdue en raison de la surchauffe, du frottement des pièces, etc.

I.3.2 Maintenance corrective (CM) :

Avec le temps, les entreprises ont commencé à adopter une approche plus proactive envers la maintenance, en mettant en place des programmes de maintenance corrective.

La maintenance corrective intervient après la détection d'une défaillance et vise à remettre un équipement en état de fonctionner normalement. Les étapes de la maintenance corrective sont les suivantes :

- Détection de la défaillance : Identification du problème.
- Diagnostic : Analyse pour déterminer la cause de la défaillance.
- Élimination de la pièce défectueuse : Retrait de la pièce causant la panne.
- Commande de la pièce de rechange : Acquisition de la nouvelle pièce.
- Remplacement de la pièce : Installation de la pièce de rechange.
- Test de fonctionnement : Vérification du bon fonctionnement de l'équipement.
- Reprise de l'utilisation de la machine : Retour à l'opération normale.

I.3.2.1 Avantages de la Maintenance Corrective

- Résolution proactive des problèmes : Aide les équipes de maintenance à résoudre les problèmes avant que des retards de production ou des interruptions de service ne se produisent.
- Réduction des commandes de maintenance d'urgence : Évite l'accumulation des défauts, réduisant ainsi les interventions d'urgence.
- Sécurité accrue des employés : Les machines sont réparées juste à temps et maintenues en état optimal, ce qui augmente la sécurité.

I.3.2.2 Ecueils de la Maintenance Corrective

- Dépendance problématique : S'appuyer uniquement sur la maintenance corrective peut être problématique si l'équipement n'est pas surveillé après l'achat, entraînant des pannes plus imprévisibles dont la cause est inconnue.
- Délais imprévus : Les défaillances inattendues peuvent être retardées par l'incapacité d'accéder rapidement aux matériaux nécessaires, ce qui peut entraîner des périodes d'inactivité prolongées.

I.3.3 Maintenance Prédictive (Pdm)

La maintenance prédictive (PdM) est au cœur de la gestion de la santé des systèmes. L'objectif ultime est de prévenir les pannes en surveillant en continu les conditions des équipements, et la principale barrière est le temps nécessaire pour sa mise en œuvre plutôt que le coût de la technologie [4]. La maintenance prédictive repose sur l'utilisation de technologies avancées telles que l'IoT, les capteurs intelligents et l'apprentissage automatique pour collecter et analyser les données en temps réel sur l'état et la performance des équipements.

I.3.3.1 Avantages de la Maintenance Prédictive (PdM)

- Réduction des pannes non planifiées : Diminue la fréquence des pannes en prévoyant les défaillances potentielles avant qu'elles ne surviennent.
- Économies de coûts : Évite les coûts associés à la maintenance préventive lorsque les pièces sont remplacées trop tôt.

- Technologies émergentes : De récentes avancées technologiques rendent la PdM à la fois performante et abordable, notamment grâce à l'IoT et aux techniques de Big Data pour le prétraitement des données.

I.3.3.2 Ecueils de la Maintenance Prédictive (PdM) :

- Les données peuvent être mal interprétées, ce qui peut conduire à des demandes de maintenance incorrectes.
- Coût élevé pour établir un système IoT complet avec des capteurs, des coûts de transmission et d'analyse.
- L'analyse prédictive peut ne pas prendre en compte les informations contextuelles, telles que l'âge de l'équipement ou les conditions météorologiques.
- La maintenance prédictive peut décourager l'inspection physique proactive et l'entretien de l'équipement.
- Les activités de maintenance préventive peuvent être déclenchées par des calendriers plutôt que par l'état réel de la machine.

I.3.4 Maintenance Proactive et Autonome :

Cette évolution démontre l'importance croissante de la technologie et de l'innovation dans le domaine de la maintenance industrielle, avec un passage progressif de réactif à préventif, puis à prédictif et enfin à proactif. Cette transformation a permis aux entreprises de réduire les coûts, d'optimiser les performances et d'augmenter la disponibilité des équipements, contribuant ainsi à renforcer leur compétitivité sur le marché.

- La maintenance proactive va au-delà de la simple prédiction des pannes en proposant des solutions pour éviter ces pannes avant même qu'elles ne se produisent.
- Les avancées telles que la maintenance autonome, où les machines sont capables de diagnostiquer et de réparer elles-mêmes les problèmes, représentent l'avenir de la maintenance industrielle.

I.4 Industrie 4.0

L'expression "Industrie 4.0" a été présentée pour la première fois lors de la foire de Hanovre en 2011 [6], marquant ainsi le début d'une quatrième révolution industrielle dans le secteur manufacturier à l'échelle mondiale. Cette révolution vise principalement à garantir la compétitivité de l'industrie allemande, mais son influence s'étend bien au-delà des frontières nationales.

"Industrie 4.0" fait référence à cette quatrième révolution industrielle, caractérisée par des avancées technologiques majeures. Tout comme les révolutions industrielles précédentes, cette phase est dominée par des innovations techniques. Alors que la mécanisation et l'électrification des processus de fabrication ont marqué les deux premières révolutions, la troisième étape, caractérisée par une informatisation et une automatisation accrue, évolue doucement vers cette nouvelle ère.

L'essence de l'Industrie 4.0 réside dans l'intégration technique des systèmes cyber-physiques dans les processus de fabrication, ainsi que dans l'incorporation de l'Internet des Objets (IoT) et des services dans les opérations industrielles. Ces nouvelles technologies auront un impact significatif sur la création de valeur, l'organisation du travail, les services en aval et les modèles économiques des entreprises.

Au cœur de l'Industrie 4.0 se trouve le concept d'usine intelligente, qui joue un rôle central dans la définition de la vision de cette nouvelle ère industrielle. Les usines intelligentes intègrent des technologies avancées telles que l'IoT, l'intelligence artificielle et l'automatisation pour créer des environnements de production hautement efficaces, adaptables et interconnectés.

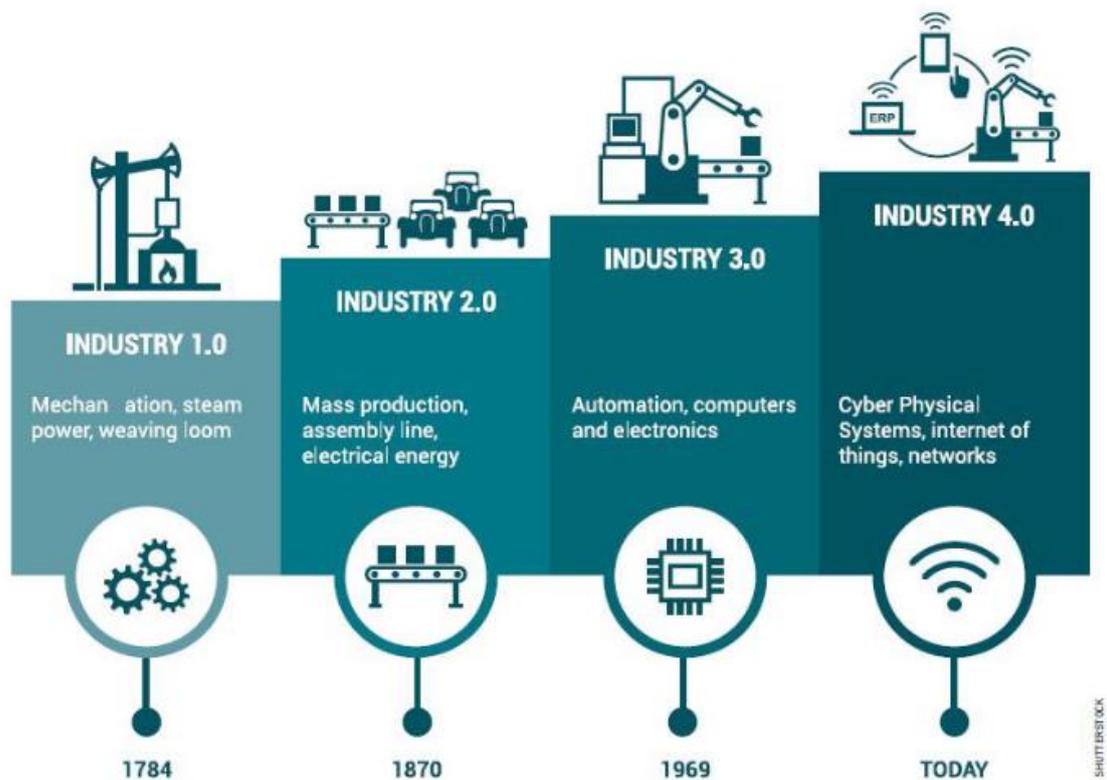


Figure I_1 convolution de l'industrie [6]

I.4.1 Avantages et inconvénients :

Certes, l'industrie 4.0 se traduit par des avantages productifs, mais il n'en demeure pas moins que les aspects innovants masquent d'importants contrastes. [6]

Les technologies émergentes et expérimentales de l'industrie 4.0 entraîneront de profonds changements dans la société, elles devront donc être ajustées et réglementées par de nouvelles lois du travail.

Pour mieux comprendre cette prochaine réalité de l'industrie, nous vous détaillons ses principaux avantages et inconvénients.

a) Avantages :

- L'automatisation améliore tant la qualité que la quantité des produits, conduisant à une production plus efficace et plus fiable.
- Les processus automatisés permettent de réduire les coûts, les délais et les erreurs, tout en minimisant les risques liés à la production.

- La sécurité des travailleurs est renforcée grâce à la réduction des tâches dangereuses et à la mise en place de mesures de sécurité intégrées.
- L'accès instantané aux données numériques facilite la prise de décision et optimise la gestion des opérations.
- L'adoption des technologies de l'industrie 4.0 renforce la compétitivité des entreprises en leur permettant de répondre de manière plus agile aux exigences changeantes du marché.
- Les entreprises peuvent offrir des services plus personnalisés à leurs clients, en s'adaptant mieux à leurs besoins spécifiques.
- En optimisant l'utilisation des ressources, les entreprises réduisent leur empreinte environnementale, contribuant ainsi à la durabilité de l'industrie.

b) Inconvénients :

- L'adoption initiale de technologies de pointe nécessite un investissement financier significatif.
- La rapidité de l'évolution technologique oblige les entreprises à maintenir un rythme constant de mise à jour, ce qui peut être difficile à suivre pour certaines organisations.
- Une fracture économique peut se creuser entre les entreprises qui parviennent à s'adapter aux nouvelles technologies et celles qui restent à la traîne.
- Le besoin de spécialistes qualifiés pour superviser et optimiser les processus automatisés peut poser des défis en matière de recrutement et de formation.
- L'automatisation peut entraîner une diminution temporaire de l'emploi, car certaines tâches sont remplacées par des machines.
- La dépendance croissante à la technologie expose les entreprises à des risques potentiels, tels que les cyberattaques ou les pannes de système.

I.4.2 Technologies clés de l'industrie 4.0

I.4.2.1 IoT

L'internet des objets (Internet of Things IoT) peut être compris comme le réseau mondial et omniprésent qui aide et fournit la fonctionnalité d'intégration du monde physique. Cela se fait par la collecte, le traitement et l'analyse des données générées par les capteurs de l'IoT, qui seront présentes dans toutes les choses et intégrées par le réseau de communication public. L'Internet des objets (IoT) peut être compris comme l'ensemble des technologies de

l'information et de la communication (TIC). Le terme IoT a été créé en 1999 par le pionnier britannique de la technologie Kevin Ashton [7] pour développer un système dans lequel des objets physiques pourraient être connectés à l'Internet via des capteurs. Il a inventé ce terme pour déterminer l'importance des étiquettes d'identification par radiofréquence (RFID) utilisées dans les chaînes d'approvisionnement vers l'internet pour suivre les marchandises sans aucune intervention humaine. L'écosystème de IoT est constitué d'objets physiques, qui sont connectés et accessibles sur l'internet. Les "choses" de IoT pourraient être une personne ou tout objet doté d'un capteur intégré avec une adresse IP attribuée qui peut collecter et échanger les informations sur le réseau sans aucune assistance humaine (Madakam et al.2015). La technologie intégrée dans le CPS permet sa connexion avec le monde physique pour la capture de données volumineuses et garantit une sécurité accrue de IoT ainsi qu'une efficacité accrue du CPS. IoT prend rapidement de l'ampleur pour aider les industries à accroître la précision et l'exactitude des processus, à réduire les coûts et à percevoir les avantages de l'information en temps réel, ce qui permettrait de prendre des décisions en connaissance de cause. IoT offre la possibilité de contrôler les performances réelles et les indicateurs clés de performance d'une organisation. Cela leur permet de créer leurs systèmes de produits-services et de démêler le potentiel d'innovation du système grâce à IoT [7].

I.4.2.2 BIG Data :

Le terme Big Data désigne le grand volume de données - structurées et non structurées – qui font partie des entreprises. Le Big Data peut-être utile dans la recherche d'informations permettant d'optimiser le processus de décision et d'améliorer les stratégies commerciales.

I.4.3 Intelligence Artificielle (IA) et Machine Learning (ML)

Ces technologies sont utilisées pour analyser de grandes quantités de données provenant de diverses sources afin de détecter des modèles, d'optimiser les processus de production, de prévoir les pannes d'équipements et de prendre des décisions autonomes.

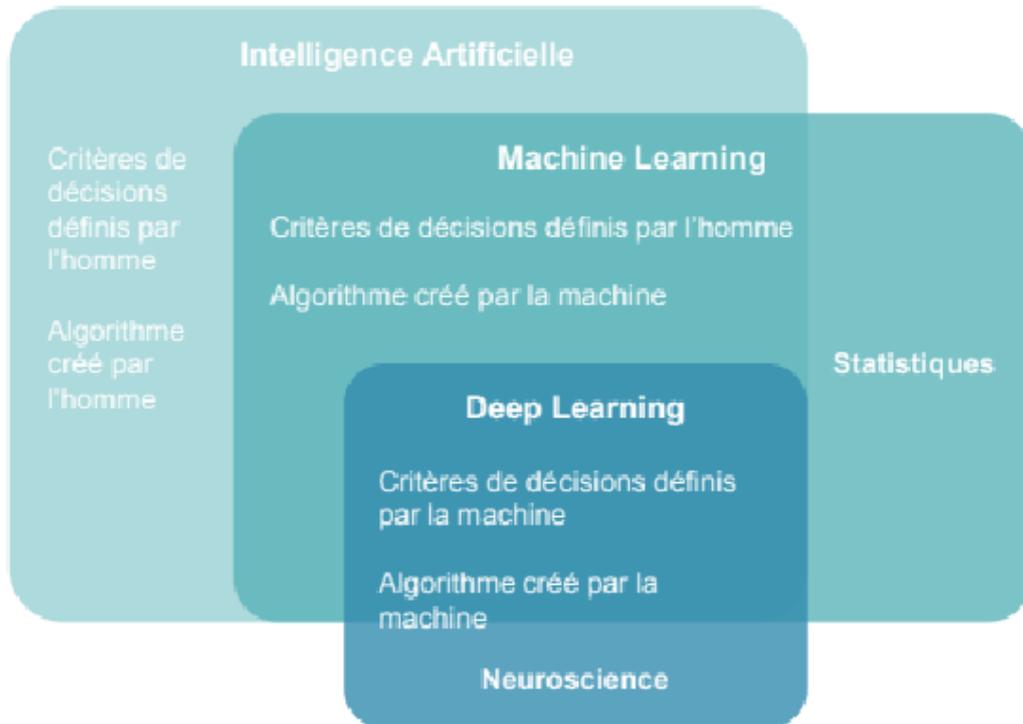


Figure I_2 Organisation des composants de l'Intelligence Artificielle [8]

Par exemple, la promesse de maintenance prédictive est rendue possible grâce à deux composants forts de l'IA, le machine learning et le deep learning. Dans le premier cas, l'expertise reste humaine, le but étant de découvrir des patterns de données (modèles schématiques) et d'effectuer des prédictions en se basant sur des statistiques, du forage de données et de l'analyse.

Dans le DL, l'expertise n'est même plus apportée par l'homme mais directement par la machine via un système d'apprentissage et de classification. Pour exemple, les assistants vocaux (Siri et Alexa utilisent déjà ces principes). [8]

I.4.4 Intégration de l'IoT dans la maintenance prédictive

1. Collecte de données en temps réel :

L'IoT permet la collecte continue de données provenant d'une variété de capteurs et d'appareils installés sur les équipements industriels.

Ces capteurs peuvent surveiller divers paramètres tels que la température, la pression, la vibration, les niveaux de fluides, etc., fournissant ainsi des informations précieuses sur l'état de santé des équipements.

2. Surveillance proactive des équipements :

Grâce à l'IoT, les opérateurs peuvent surveiller en temps réel les performances des équipements et détecter les anomalies ou les signes de défaillance potentielle avant qu'elles ne se produisent.

Cela permet une intervention précoce pour effectuer des réparations ou des maintenances préventives, évitant ainsi des temps d'arrêt imprévus et coûteux.

3. Diagnostic avancé des pannes :

En combinant les données collectées par l'IoT avec des algorithmes d'analyse avancés, il est possible d'effectuer un diagnostic précis des causes sous-jacentes des pannes ou des défaillances potentielles.

Cette capacité à identifier rapidement les problèmes permet d'optimiser les plans de maintenance et de réduire les temps d'arrêt non planifiés.

4. Optimisation des plans de maintenance :

L'IoT fournit des informations en temps réel sur les conditions de fonctionnement des équipements, ce qui permet une planification plus précise et optimisée des activités de maintenance.

Les entreprises peuvent passer d'une approche de maintenance préventive basée sur des calendriers fixes à une maintenance prédictive basée sur l'état réel des équipements, réduisant ainsi les coûts tout en maximisant la disponibilité opérationnelle.

5. Suivi à distance et interventions à distance :

L'IoT permet également le suivi à distance des équipements, ce qui permet aux équipes de maintenance d'accéder aux données et de diagnostiquer les problèmes même à distance.

Dans certains cas, des interventions à distance peuvent être effectuées pour résoudre les problèmes mineurs sans nécessiter de déplacement physique sur site, ce qui réduit les temps d'arrêt et les coûts associés.

Dans le cadre de la maintenance prédictive, il est crucial d'identifier les différents types de défauts qui peuvent survenir sur un équipement. Voici une liste non exhaustive des principaux types de défauts :

I.5 Types de Défauts sur les Équipements

I.5.1 Défauts Mécaniques :

- Usure : Détérioration progressive des pièces due à leur utilisation continue.
- Fissures : Apparition de fissures dans les matériaux, souvent causées par des contraintes excessives ou des cycles de charge répétés.
- Déformation : Changement de la forme originale des pièces en raison de charges mécaniques ou thermiques.
- Casse : Rupture soudaine d'une pièce due à un effort mécanique supérieur à sa résistance.

I.5.2 Défauts Électriques :

- Court-circuit : Contact accidentel entre deux conducteurs, provoquant une circulation excessive de courant.
- Surtension : Tension électrique plus élevée que la normale, pouvant endommager les composants.
- Sous-tension : Tension électrique inférieure à la normale, pouvant entraîner une mauvaise performance des équipements.
- Défauts d'isolement : Détérioration de l'isolement électrique, conduisant à des fuites de courant ou à des courts-circuits.

I.5.3 Défauts Thermiques :

- Surchauffe : Élévation excessive de la température due à une mauvaise dissipation de la chaleur ou à une surcharge.
- Défauts de refroidissement : Insuffisance du système de refroidissement, entraînant une surchauffe des composants.

I.5.4 Défauts Hydrauliques :

- Fuites : Perte de fluide hydraulique due à une mauvaise étanchéité.
- Blocage : Obstruction dans les canalisations ou les valves, empêchant le fluide de circuler correctement.

- Cavitation : Formation de bulles de gaz dans le fluide, pouvant endommager les composants internes.

I.5.5 Défauts de Lubrification :

- Insuffisance de lubrification : Quantité de lubrifiant insuffisante, entraînant une usure excessive.
- Contamination : Présence d'impuretés dans le lubrifiant, affectant son efficacité.
- Dégradation : Détérioration des propriétés du lubrifiant au fil du temps, réduisant sa capacité à protéger les pièces.

I.5.6 Défauts Environnementaux :

- Corrosion : Dégradation des matériaux due à des réactions chimiques avec l'environnement (humidité, sel, etc.).
- Pollution : Accumulation de poussière ou de saleté, affectant le fonctionnement des composants.
- Vibrations : Vibrations excessives pouvant entraîner une usure prématurée ou des fissures.

I.5.7 Défauts de Contrôle et de Communication :

- Défauts de capteurs : Capteurs défectueux donnant des informations incorrectes.
- Défauts de communication : Problèmes dans la transmission des données entre les capteurs et le système de contrôle.

I.6 Conclusion

En conclusion, ce chapitre a exploré les principes fondamentaux de la maintenance industrielle dans le contexte de l'ère de l'Industrie 4.0. Nous avons vu comment les avancées technologiques telles que l'Internet des Objets (IoT), le Big Data, et l'Intelligence Artificielle (IA) ont transformé la maintenance, passant d'une approche réactive à des méthodes plus proactives et prédictives.

La maintenance prédictive (PdM) est apparue comme une évolution significative, permettant aux entreprises de prévenir les pannes grâce à une surveillance continue des équipements et à des diagnostics avancés basés sur des données en temps réel. Cette approche non seulement réduit les coûts liés aux pannes non planifiées et à la maintenance préventive, mais améliore également la sécurité des opérateurs et la durabilité environnementale.

En fin de compte, le premier chapitre offre une vue d'ensemble des principes fondamentaux de la maintenance prédictive à base d'IoT avec apprentissage automatique, en mettant en évidence son rôle central dans la transformation de l'industrie vers des opérations plus intelligentes, efficaces et durables. Il pose les bases pour les chapitres suivants qui exploreront plus en détail les aspects techniques, les applications industrielles spécifiques et les défis pratiques liés à la mise en œuvre de la maintenance prédictive dans divers secteurs.

II. CHAPITRE 2

Méthodes d'apprentissage automatique et internet des objets connectés

II.1 Introduction

Après avoir présenté les différents types de défauts qui peuvent survenir dans un système dans le chapitre précédent.

Dans ce chapitre se concentrera sur les méthodes d'apprentissage automatique et l'internet des objets (IoT). L'apprentissage automatique, ou machine Learning, est une technologie révolutionnaire qui permet aux machines d'apprendre à partir des données, sans avoir été explicitement programmées pour cela. En parallèle, l'IoT offre une connectivité sans précédent entre les appareils, facilitant la collecte et l'analyse de données en temps réel. Ce chapitre explore comment ces deux technologies peuvent être intégrées pour améliorer la maintenance prédictive, réduire les coûts et augmenter l'efficacité opérationnelle.

II.2 L'apprentissage automatique

L'apprentissage automatique (en anglais : machine Learning) est une technique d'analyse de données qui consiste à enseigner à des ordinateurs ce dont les humains sont naturellement capables : tirer des leçons de leurs expériences. Les algorithmes d'apprentissage automatique font appel à des méthodes de calcul pour « apprendre » des informations directement à partir des données sans qu'il soit nécessaire de s'appuyer sur une équation prédéterminée en tant que modèle. Les algorithmes s'adaptent et deviennent plus performants à mesure que le nombre d'échantillons disponibles pour l'apprentissage augmente [9].

L'apprentissage automatique fonctionne de la même manière. Vous récupérez l'ensemble de données d'entraînement, qui contient les données et le résultat. Utilisez-le pour formuler un modèle. Ensuite, vous introduisez des données réelles dans ce modèle pour prédire un résultat. Lorsque vous validez le résultat prévu, le modèle apprend ce qui améliore son résultat (voir la Figure II_1) [10]

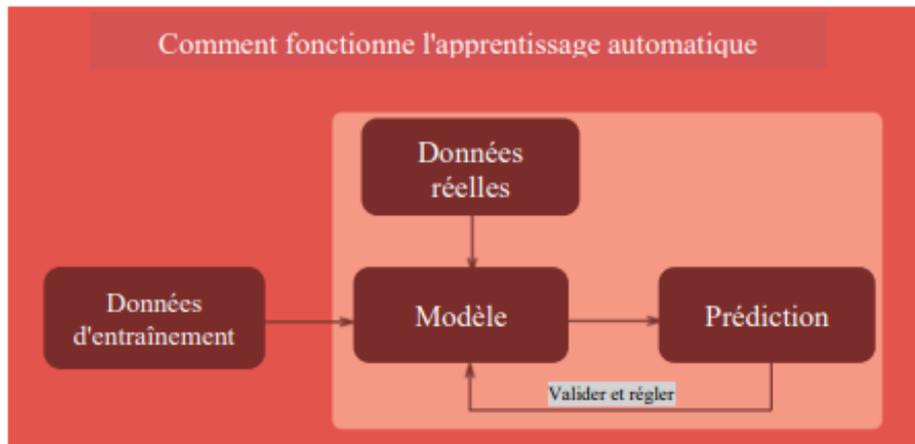


Figure II_1 Le fonctionnement général d'apprentissage automatique [10]

II.2.1 Méthodes d'apprentissage automatique

Méthodes d'apprentissage automatique Les méthodes d'apprentissage automatique sont utilisées pour que le système apprenne en utilisant des méthodes comme l'apprentissage supervisé et l'apprentissage non supervisé qui sont ensuite classées dans des méthodes comme la classification, la régression et le regroupement (voir Figure II_2).

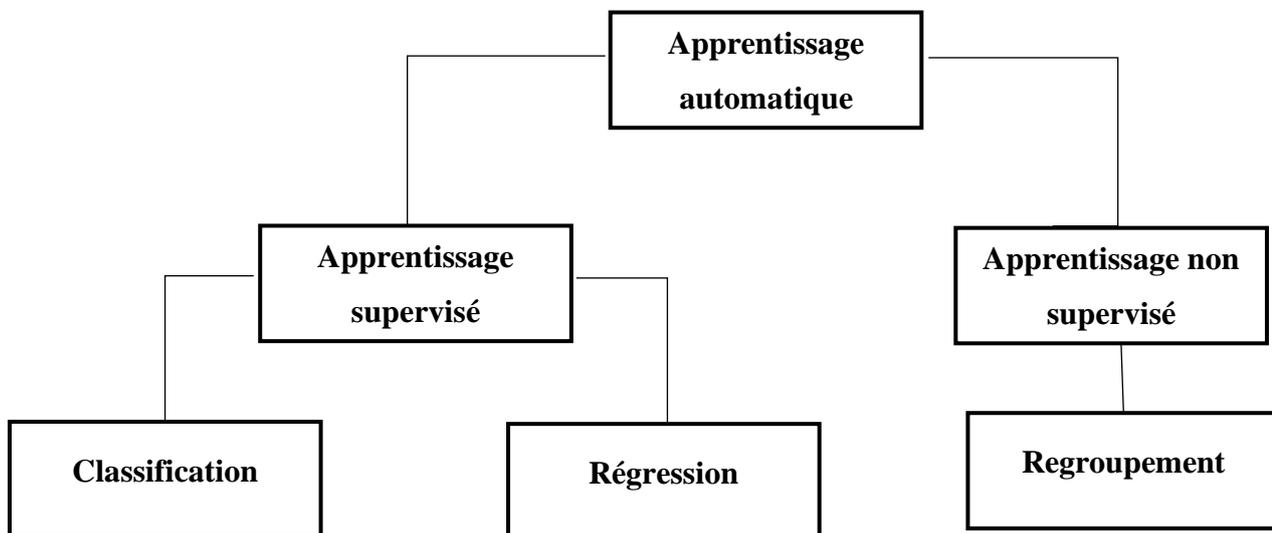


Figure II_2 Méthodes d'apprentissage automatique

II.2.1.1 L'apprentissage supervisé :

L'apprentissage supervisé est une catégorie d'algorithme d'apprentissage automatique qui est fondé sur l'ensemble de données étiquetées. L'analyse prédictive est réalisée pour cette catégorie d'algorithmes où le résultat de l'algorithme connu sous le nom de variable dépendante dépend de la valeur des variables de données indépendantes. Il est fondé sur l'ensemble de données d'entraînement et s'améliore par itérations (voir la Figure II_3) [11].

Les algorithmes d'apprentissage supervisé couramment utilisés : arbre de décision (decision tree), forêt aléatoire (random forest), K-NN (K-Nearest Neighbor), SVM (Support Vector Machine), ANN, RL (régression logistique)...

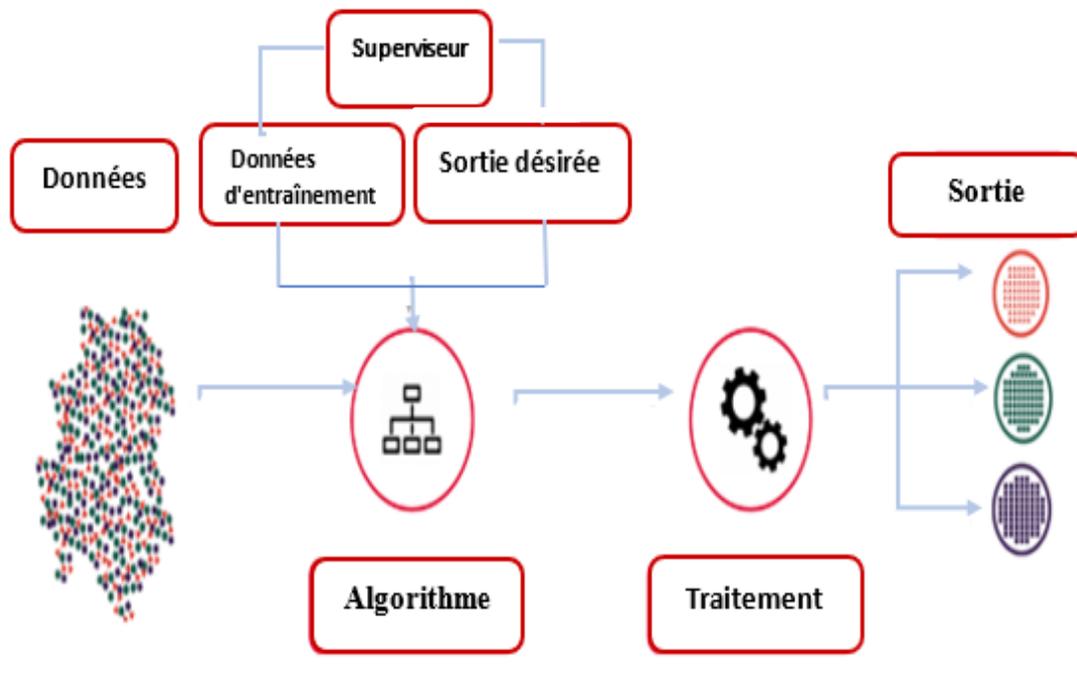


Figure II_3 Fonctionnement de l'apprentissage supervisé pour un problème de classification.

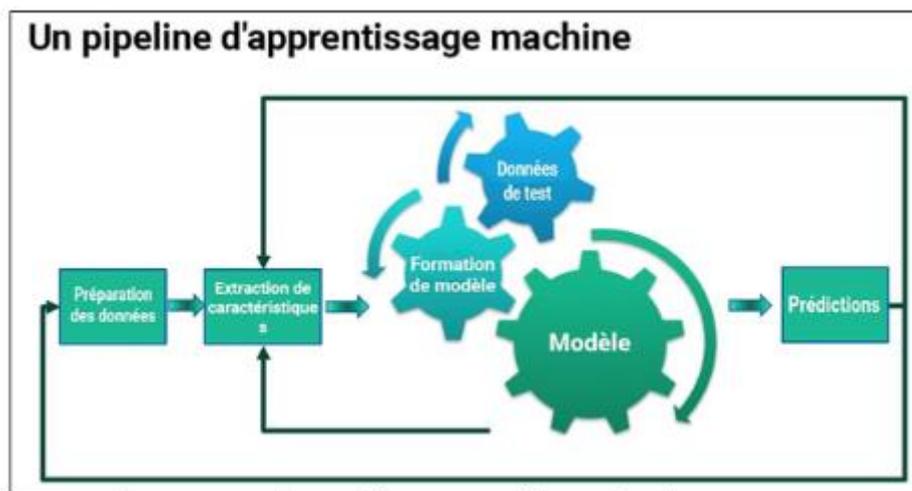


Figure II_4 Phase d'apprentissage du modèle d'apprentissage supervisé.

Il existe principalement deux catégories d'apprentissage supervisé, telles que la régression et la classification

II.2.1.1.1 Classification

Ces tâches consistent à attribuer une classe à des objets. Par exemple, dans le milieu bancaire, on peut identifier si une transaction est frauduleuse ou non frauduleuse de manière automatique. On parle de détection d'anomalie. Dans l'industrie, on peut déterminer si oui ou non une machine est susceptible de tomber en panne. On associe une réponse prédéfinie (oui ou non, jaune, rouge, vert ou bleu) à un objet, avant de demander à l'algorithme de réaliser cette classification [12] et de répondre à la question « quelle classe ? ». La classification se divise en quatre catégories qui sont : [13] :

- Classification binaire : qui fait référence aux tâches de classification qui ont deux étiquettes de classe (oui/non). Classification multi-classes : fait référence aux tâches de classification qui ont plus de deux étiquettes de classe.
- La classification multi-étiquettes : fait référence aux tâches de classification qui ont deux étiquettes de classe ou plus, où une ou plusieurs étiquettes de classe peuvent être prédites pour chaque exemple. Prenons l'exemple de la classification de photos, où une photo donnée peut avoir plusieurs objets dans la scène et un modèle peut prédire la présence de plusieurs objets connus dans la photo, tels que "vélo", "pomme", "personne", etc.

- La classification déséquilibrée : fait référence aux tâches de classification où le nombre d'exemples dans chaque classe est inégalement réparti. En règle générale, les tâches de classification déséquilibrées sont des tâches de classification binaires dans lesquelles la majorité des exemples de l'ensemble de données d'apprentissage appartiennent à la classe normale et une minorité d'exemples appartiennent à la classe anormale.

II.2.1.1.2 Régression

Ici, on n'attribue pas une classe mais une valeur mathématique : un pourcentage ou une valeur absolue. Par exemple, une probabilité pour une machine de tomber en panne (15 %, 20 %, etc.) ou le prix de vente idéal d'un appartement en fonction de critères comme la surface, le quartier, etc. [12] et répondre à la question « combien ? ».

II.2.1.2 L'apprentissage non supervisé

L'apprentissage non supervisé identifie des modèles cachés ou des structures intrinsèques dans les données. Il est utilisé pour tirer des conclusions à partir d'ensembles de données composés de données d'entrée sans réponses labellisées. Le regroupement (clustering) est la technique d'apprentissage non supervisé la plus répandue. Le regroupement est utilisé pour effectuer une analyse exploratoire des données afin de trouver des modèles cachés ou des regroupements dans les données L'analyse de séquence génomique, l'étude de marché et la reconnaissance d'objets sont des exemples d'applications d'analyse de cluster [9].

Les algorithmes couramment utilisés pour le regroupement sont : la méthode des k-moyennes et k-médoïdes, le regroupement hiérarchique, les modèles de mélanges gaussiens, les modèles de Markov cachés, les cartes auto-organisatrices, le regroupement c-moyennes flou, le regroupement soustractif [9] et réseaux neuronaux.

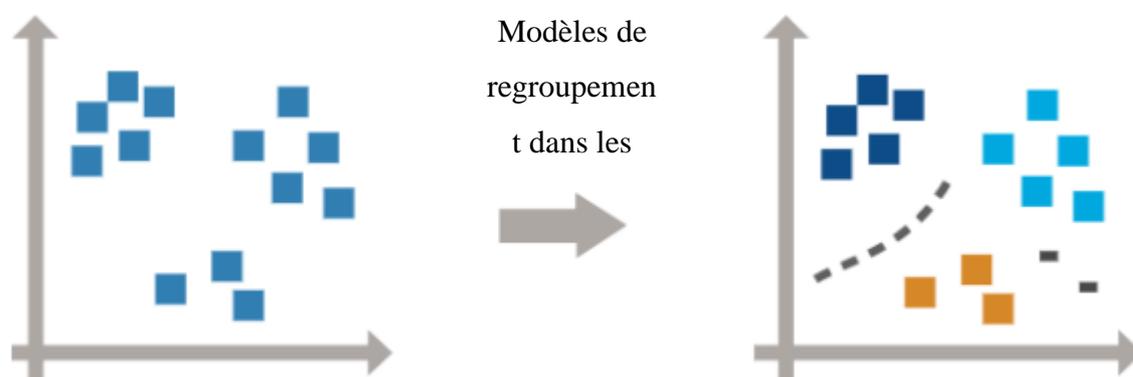


Figure II_5 Le regroupement identifie des modèles cachés dans vos données.

Dans notre étude du système de maintenance prédictive basé sur les méthodes ML, nous avons utilisé deux méthodes d'apprentissage automatique qui sont Réseaux de Neurones et la Régression logistique.

II.3 Régression logistique

La régression logistique ou logistique régression (LR) en anglais est un modèle statistique permettant d'étudier les relations entre un ensemble de variables qualitatives X_i et une variable qualitative Y . Un modèle de régression logistique permet aussi de prédire la probabilité qu'un événement arrive (valeur de 1) ou non (valeur de 0) à partir de l'optimisation des coefficients de régression. Ce résultat varie toujours entre 0 et 1. Lorsque la valeur prédite est supérieure à un seuil, l'événement est susceptible de se produire, alors que lorsque cette valeur est inférieure au même seuil, il ne l'est pas [14].

II.4 Réseaux de neurones artificiels

En 1943, McCulloch et Pitts ont proposé des neurones formels imitant les neurones biologiques et capables de mémoriser des fonctions booléennes simples [15]. Les réseaux de neurones artificiels réalisés à partir de ce type de neurones sont inspirés du système nerveux. Un réseau neurones artificiel est une série d'algorithmes qui s'efforce de reconnaître les relations sous-adjacentes dans un ensemble de données à travers un processus qui imite la façon dont le cerveau humain fonctionne. Ils sont conçus pour reproduire certaines caractéristiques de la mémoire biologique en étant :

- Massivement parallèles.
- Capables d'apprendre.
- Capables de mémoriser les informations dans les connexions inter-neuronales.
- Capables de traiter des informations incomplètes.

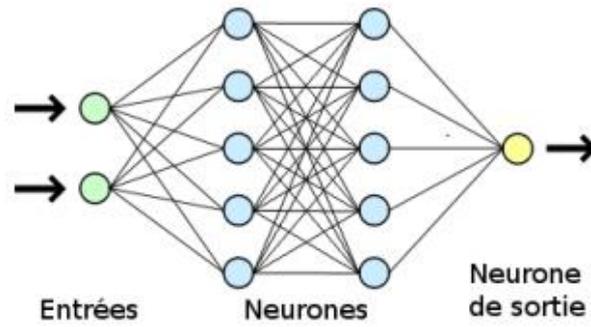


Figure II_6 Réseaux de neurones artificiels [16].

II.4.1 Structure

Les réseaux de neurones artificiels (ANN) sont des modèles computationnels inspirés par la structure et le fonctionnement des neurones dans le cerveau humain.

Voici une structure de base d'un modèle ANN

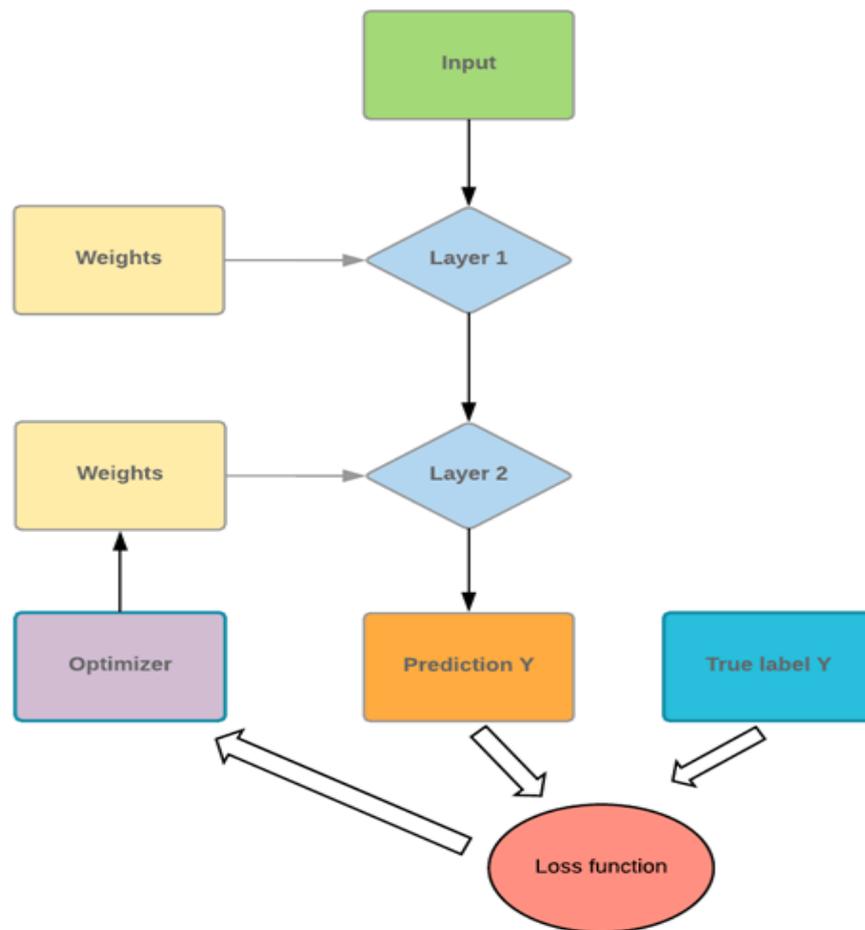


Figure II_7 Diagramme de ANN

II.4.2 Principe de fonctionnement d'algorithme

➤ **Entrée des données (Input Layer) :**

- Les données brutes (features) sont introduites dans le réseau à travers les neurones de la couche d'entrée.
- Chaque neurone de la couche d'entrée correspond à une caractéristique spécifique des données.

➤ **Propagation (Hidden Layers) :**

- Les données sont ensuite transmises à travers une ou plusieurs couches cachées.
- Chaque neurone d'une couche cachée reçoit les entrées pondérées de la couche précédente, applique une fonction d'activation pour introduire de la non-linéarité, et transmet le résultat à la couche suivante.

➤ **Fonction d'activation :**

- Les fonctions d'activation courantes incluent ReLU (Rectified Linear Unit), Sigmoid, Tanh, etc.
- Elles permettent au réseau de modéliser des relations non linéaires.

➤ **Sortie (Output Layer) :**

- La couche de sortie génère les prédictions du réseau.
- Dans une tâche de classification binaire, la couche de sortie peut avoir un seul neurone avec une fonction d'activation sigmoïde, produisant une probabilité. Pour une classification multi classes, la couche de sortie utilise souvent la fonction segmoid.

➤ **Propagation vers l'avant (Forward Propagation) :**

- Le processus de calcul de la sortie en passant les données d'entrée à travers le réseau est appelé propagation vers l'avant.

➤ **Calcul de l'erreur (Loss Function) :**

- Une fonction de perte (par exemple, l'erreur quadratique moyenne pour les régressions ou l'entropie croisée pour les classifications) calcule la différence entre les prédictions du réseau et les valeurs réelles

II.5 L'internet des objets

II.5.1 Définition

L'internet des objets est le concept de connexion de n'importe quel appareil à internet et à d'autres appareils connectés. L'IoT est un réseau géant d'objets et de personnes connectés, qui collectent et partagent tous des données sur la façon dont ils sont utilisés et sur l'environnement qui les entoure (voir **Figure II_8**) [17, 18].

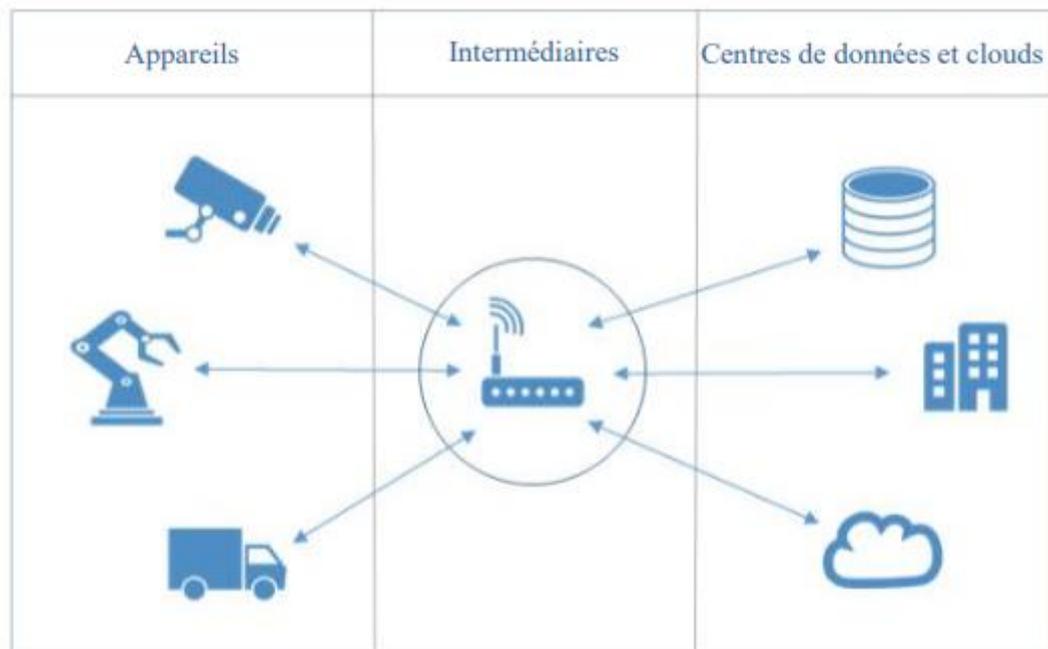


Figure II_8 Architecture de base d'IoT.

II.5.2 Fonctionnement de l'IoT dans la Maintenance Prédicative

1. Collecte de Données :

- Les capteurs IoT surveillent en continu les paramètres opérationnels des machines.
- Les données collectées sont envoyées aux passerelles IoT.

2. Transmission et Stockage des Données :

- Les passerelles transmettent les données via des réseaux de communication sécurisés aux serveurs cloud ou aux dispositifs d'Edge computing .
- Les données sont stockées et disponibles pour une analyse ultérieure.

3. Analyse des Données :

- Les données sont analysées en utilisant des algorithmes d'intelligence artificielle et de Machine Learning pour identifier des modèles, des tendances et des anomalies.
- Les algorithmes peuvent être entraînés à reconnaître les signes précurseurs de pannes basés sur des historiques de données et des caractéristiques spécifiques des équipements.

- Les analyses permettent de détecter des anomalies qui pourraient indiquer une défaillance imminente.
- Les systèmes peuvent prévoir quand une machine est susceptible de tomber en panne, en fonction des données et des modèles identifiés.

4. Actions Automatisées et Alertes :

- Des alertes sont envoyées aux techniciens et gestionnaires pour qu'ils puissent planifier une maintenance proactive.
- Les systèmes peuvent également automatiser certaines actions, comme ajuster les paramètres de la machine ou arrêter l'équipement pour éviter des dommages supplémentaires.

5. Intervention et Suivi :

- Les techniciens interviennent pour effectuer la maintenance nécessaire, en suivant les recommandations fournies par le système IoT.
- Toutes les interventions et les résultats sont enregistrés pour améliorer les futures analyses et prévisions.

II.5.3 L'importance d'IoT

L'importance de l'IoT devient considérable, puisqu'il s'agit de la première véritable évolution de l'internet. Celle-ci donnera lieu à des applications révolutionnaires capables de transformer profondément notre mode de vie, et notre façon d'apprendre, de travailler et de nous divertir. L'IoT a déjà doté l'internet des capacités sensorielles (température, pression, vibration, luminosité, humidité, tension), ce qui nous permet d'anticiper plutôt que de simplement réagir. En outre, l'internet couvre maintenant des endroits jusqu'alors inaccessibles. Des patients ingèrent même des dispositifs connectés qui aident les médecins à diagnostiquer certaines pathologies et à en déterminer les causes, des capteurs extrêmement miniaturisés peuvent être placés sur des plantes, des animaux et des sites géologiques, et connectés à l'internet [19].

II.6 Conclusion

Ce chapitre a fourni une vue d'ensemble des méthodes d'apprentissage automatique et de l'internet des objets (IoT), en démontrant comment ces technologies peuvent être appliquées à la maintenance prédictive. L'apprentissage automatique, avec ses approches supervisées et non supervisées, permet de développer des modèles capables de prédire les défaillances des équipements et de recommander des actions préventives. L'intégration de l'IoT facilite la collecte de données en temps réel et leur transmission pour une analyse avancée.

Dans ce chapitre, nous avons présenté deux méthodes d'apprentissage automatique que nous avons utilisé dans notre réalisation pratique pour détecter et classifier les défauts de système de maintenance. Les deux algorithmes qui seront utilisés sont réseaux de neurones artificiels et ANN, et la régression logistique et l'IoT pour la télésurveillance de notre système.

III. CHAPITRE 3

Mise en œuvre de la méthode et résultats de simulation

III.1 Introduction

Après avoir montré et expliqué les techniques d'apprentissage automatique utilisées dans notre projet, dans ce chapitre, nous allons décrire la mise en œuvre de notre méthode. Nous parlerons de l'extraction des paramètres, de l'environnement de développement « Google Colab ». Nous présenterons également les résultats de la simulation (détection et classification) et terminerons par l'explication de chaque système.

III.2 Environnement de Développement

III.2.1 Google collab

Colaboratory, souvent raccourci en "Colab", est un produit de Google Research. Colab permet à n'importe qui d'écrire et d'exécuter le code Python de son choix par le biais du navigateur. C'est un environnement particulièrement adapté à l'apprentissage automatique, à l'analyse de données et à l'éducation [24]. La figure suivante représente une fenêtre de Google Colab

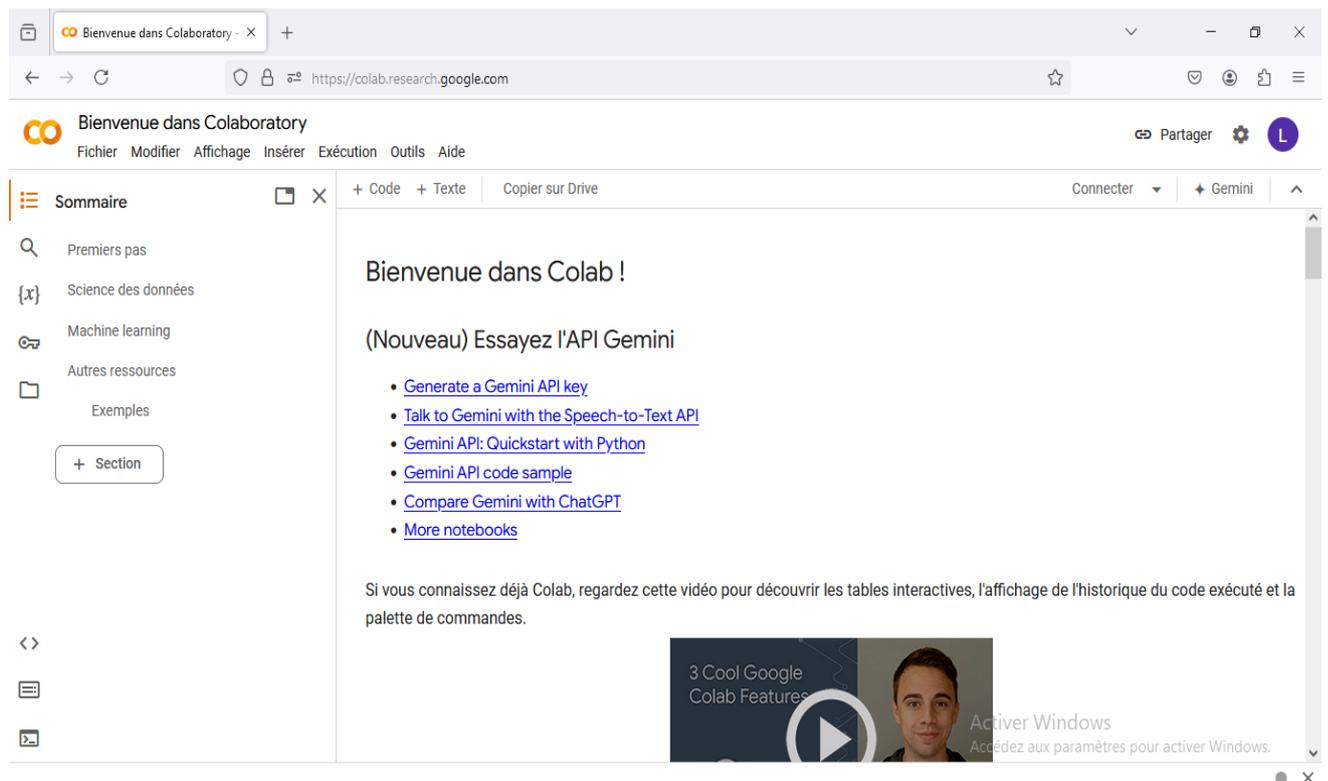


Figure III_1 fenêtre de google collab

III.2.2 Visual Studio Code

Visual Studio Code, ou VSCODE, est un éditeur de code pour le développement informatique d'applications, logiciels, sites web et services applicatifs. Que vous travailliez sur des projets en Javascript, Python, Java, Ruby, C/C++, JSON, PowerShell, HTML/CSS, C#...cet éditeur puissant et extensible fournit un environnement de développement optimisé pour chaque langage.

Ce qui distingue Visual Studio Code, c'est sa polyvalence, car il fonctionne de manière transparente sur différentes plateformes, offrant aux développeurs la liberté de travailler sur leurs projets n'importe où. Le logiciel est disponible gratuitement et téléchargeable sur les ordinateurs Windows, mac OS et Linux.[25]

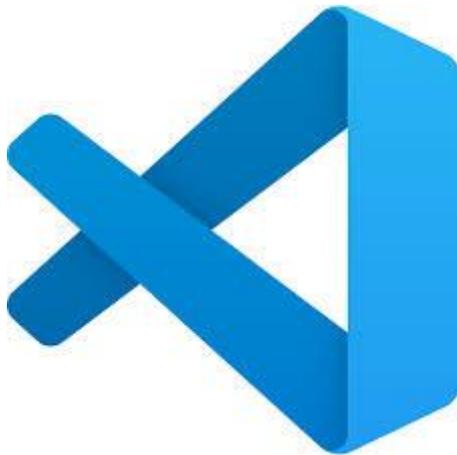


Figure III.2 Visual Studio Code

III.2.3 Python

Python est un langage de programmation polyvalent et puissant, créé en 1989 par Guido van Rossum aux Pays-Bas, nommé d'après la série télévisée Monty Python's Flying Circus. La première version publique a été publiée en 1991, et la dernière version majeure, Python 3.11, est sortie en octobre 2022. Python 2 n'est plus maintenu. Organisé par la Python Software Foundation, Python fonctionne sur divers systèmes d'exploitation, du Raspberry Pi aux supercalculateurs, et est gratuit, pouvant être installé sur un nombre illimité d'appareils, y compris les téléphones. En tant que langage de haut niveau et interprété, Python ne nécessite pas de compilation préalable, contrairement à des langages comme le C ou le C++. Orienté

objet, il facilite la modélisation d'entités réelles et est apprécié pour sa lisibilité, sa simplicité d'utilisation et son vaste écosystème de bibliothèques open-source. [26]



Figure III.5 logo de python

III.2.4 Pandas :

Pandas est une bibliothèque Python développée depuis 2008, offrant des structures de données rapides, flexibles et intuitives pour travailler avec des données relationnelles ou étiquetées. Elle vise à combler l'écart entre Python et les plateformes de calcul statistique spécifiques, en proposant des fonctionnalités telles que l'alignement automatique des données et l'indexation hiérarchique, rarement intégrées ailleurs. Initialement conçue pour l'analyse financière, Pandas est devenue un outil clé pour l'analyse de données en Python, prisé par les académiciens et les industriels. Le nom "Pandas" provient de "panel data", un terme utilisé en statistique.[27]



Figure III.3 Logo de Pandas [28]

III.2.5 Keras :

Keras est une API de réseau de neurones écrite en langage Python. Il s'agit d'une bibliothèque Open Source, exécutée par-dessus des Framework tels que TensorFlow.

Conçue pour être modulaire, rapide et simple d'utilisation, Keras a été créée par l'ingénieur François Chollet de Google. Elle offre une façon simple et intuitive de créer des modèles de Deep Learning.

Aujourd'hui, Keras est l'une des APIs de réseaux de neurones les plus utilisées pour le développement et le testing de réseaux de neurones. Elle permet de créer très facilement des « layers » pour les Neural Networks ou de mettre en place des architectures complexes.

Un Modèle Keras est constitué d'une séquence ou d'un graphique indépendant. Il existe plusieurs modules entièrement configurables et pouvant être combinés pour créer de nouveaux modèles.

L'un des avantages de cette modularité est qu'il est très facile d'ajouter de nouvelles fonctionnalités sous forme de modules séparés. Keras est donc très flexible, et adapté à la recherche et à l'innovation.[28]



Figure III.4 Logo de Keras

III.2.6 TensorFlow

TensorFlow est une bibliothèque open source de Machine Learning et de Deep Learning développée par Google. Elle permet de créer et d'exécuter des applications de Machine Learning en fournissant un ensemble d'outils pour résoudre des problèmes mathématiques complexes. TensorFlow fonctionne en représentant les calculs sous forme de graphiques de dataflow, où chaque nœud représente une opération mathématique et chaque connexion entre les nœuds est une flèche de données multidimensionnelle, appelée tensor.

TensorFlow permet de créer facilement des modèles de ML qui peuvent s'exécuter dans n'importe quel environnement. [29].



Figure III.5 TensorFlow

III.3 Phase d'apprentissage

III.3.1 Dataset

Pour entraîner le modèle, il est nécessaire d'avoir une base de données (dataset) pour la phase d'apprentissage. Dans notre étude, nous avons utilisé une base de données téléchargée depuis Internet [21]

III.3.1.1 Structure du Dataset

- Nombre d'appareils : 1169
- Type de données : Données des capteurs (variables numériques, catégorielles)
- Période d'enregistrement : Données collectées sur une période significative permettant

III.3.1.2 Variables Principales

- ID de l'appareil : Identifiant unique de chaque appareil
- Date et heure
- Capteurs : Données provenant de divers capteurs (température, vibration, pression, etc.)
- Statut de l'appareil : Indicateur de défaillance ou de bon fonctionnement

III.3.1.3 Exemples de Variables de Capteurs

- Température : Mesure de la température de l'appareil
- Vibration : Niveau de vibration détecté
- Pression : Niveau de pression enregistré

- Humidité : Mesure de l'humidité (si pertinent)
- Courant électrique : Niveau de courant électrique utilisé

III.4 Évaluation des modèles

L'évaluation des algorithmes d'apprentissage est une étape essentielle dans tous les projets. Notre modèle peut obtenir des résultats satisfaisants lorsqu'il est évalué à l'aide d'une métrique telle que le taux d'apprentissage (Accuracy), qui mesure la précision globale des prédictions. Cependant, il peut présenter des performances médiocres lorsqu'il est évalué par rapport à d'autres métriques. La plupart du temps, nous utilisons le taux d'apprentissage de la classification pour mesurer les performances de notre modèle, mais cela ne suffit pas pour juger véritablement notre modèle. Dans cette partie, nous allons aborder les différents types de mesures d'évaluation disponibles [22].

III.4.1 Taux d'apprentissage (Accuracy)

C'est le type le plus courant des méthodes d'évaluations des modèles. Il s'agit du rapport entre le nombre de prédictions correctes et le nombre total de prédictions

$$\text{Accuracy} = \frac{\text{nombre de predictions correctes}}{\text{nombre total de predictions}} \quad (3.1)$$

Ce paramètre est très utilisé dans le cas où les classes sont symétriques (elles ont le même nombre d'exemples), dans le cas contraire, il y a d'autres paramètres pour évaluer l'apprentissage de ce modèle.

III.4.2 Matrice de confusion

La matrice de confusion est un outil qui est utilisé pour décrire la performance complète du modèle [23]. Supposons que nous ayons un problème de classification binaire, c.-à-d. nous avons des échantillons appartenant à deux classes : OUI ou NON, le classifieur prédit une classe pour un échantillon donné. En testant notre classifieur en utilisant les échantillons de test, nous obtenons les quatre métriques importantes suivantes :

- Vrais positifs : Les cas dans lesquels nous avons prédit OUI et la classe réelle est également OUI.
- Vrais négatifs : Les cas dans lesquels nous avons prédit NON et la classe réelle est NON.
- Faux positifs : Les cas dans lesquels nous avons prédit OUI et la classe réelle est NON.
- Faux négatifs : Les cas dans lesquels nous avons prédit NON et la classe réelle est OUI.

Confusion matrix		Reality	
		Negative : 0	Positive : 1
Prediction	Negative : 0	True Negative : TN	False Negative : FN
	Positive : 1	False Positive : FP	True Positive : TP

Figure III.6 Matrice de confusion

D'après la matrice de confusion, on peut calculer d'autres métriques d'évaluation des performances. Ces métriques peuvent s'exprimer comme suit :

III.4.3 Recal et la précision :

La précision (precision) et le rappel (recall) sont deux métriques essentielles pour évaluer la performance des modèles de classification, que ce soit pour deux classes ou plus. Dérivées de la matrice de confusion, elles se concentrent spécifiquement sur la performance du modèle concernant les individus positifs :

$$Rappel_i = \frac{CM(i, i)}{\sum_j CM(i, j)} = \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux négatifs}} \quad (3.2)$$

$$Précision_i = \frac{CM(i, i)}{\sum_j CM(j, i)} = \frac{Vp}{Vp + Fp} \quad (3.3)$$

III.4.4 F1 score

F1 score est la moyenne harmonique entre la précision et le rappel (Recall). Il nous indique la précision de notre classifieur (combien d'exemples qu'il classe correctement), ainsi que sa robustesse. Plus le score F1 est élevé, plus le classifieur est performant. F1 score est le paramètre le plus utilisé dans les cas où les classes sont asymétriques.

$$F1_{score} = 2 \frac{(\text{Précision} \times \text{Recall})}{(\text{Recall} + \text{Précision})} \quad (3.4)$$

III.5 Résultats de simulation

Nous avons évalué la précision de détection des deux classifiés. Les performances de nos classifiés sont analysées à l'aide de la matrice de confusion. Nous avons utilisé aussi les différents paramètres d'évaluation tels que l'accuracy et le F1-score.

Après avoir effectué l'entraînement du modèle, les résultats sont représentés comme suit :

III.5.1 Paramètres d'évaluation de Régression logistique

Classes	Precision	Recall	F1_score
0	0.924	0.998	0.995
1	0.945	0.969	0.986

Tableau III_1 précision, Recall et score F1 en utilisant la régression logistique

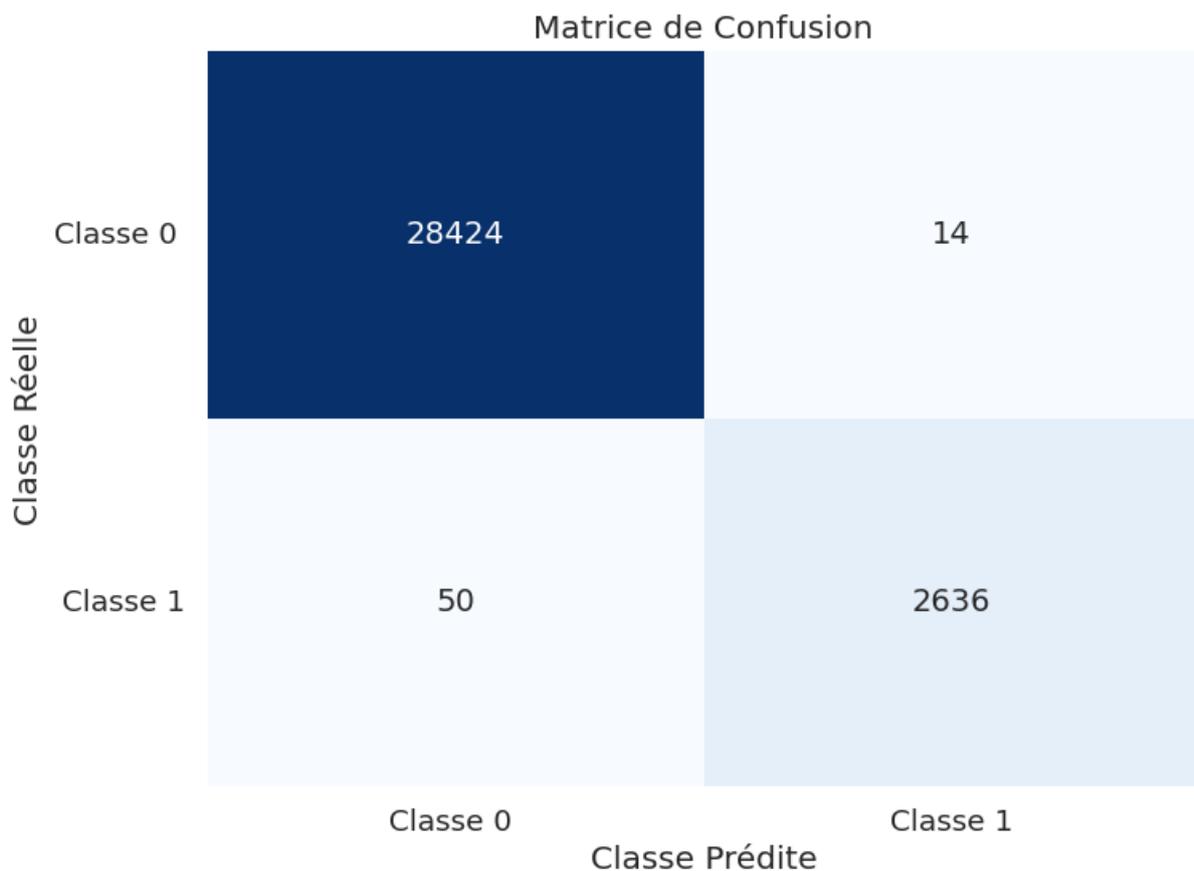


Figure III_7 matrices de confusion LR

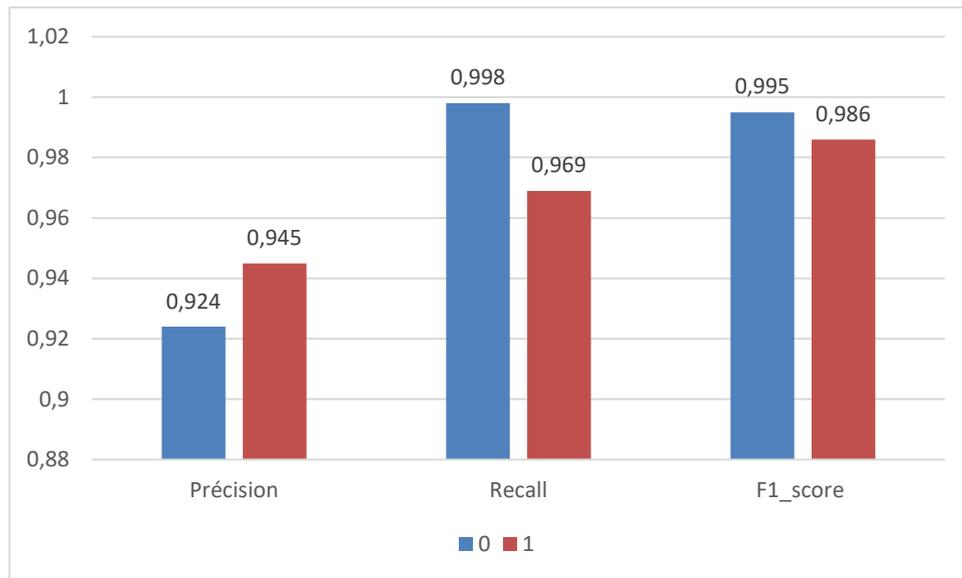


Figure III_8 Scores de Précision, Rappel et F1 par Classe

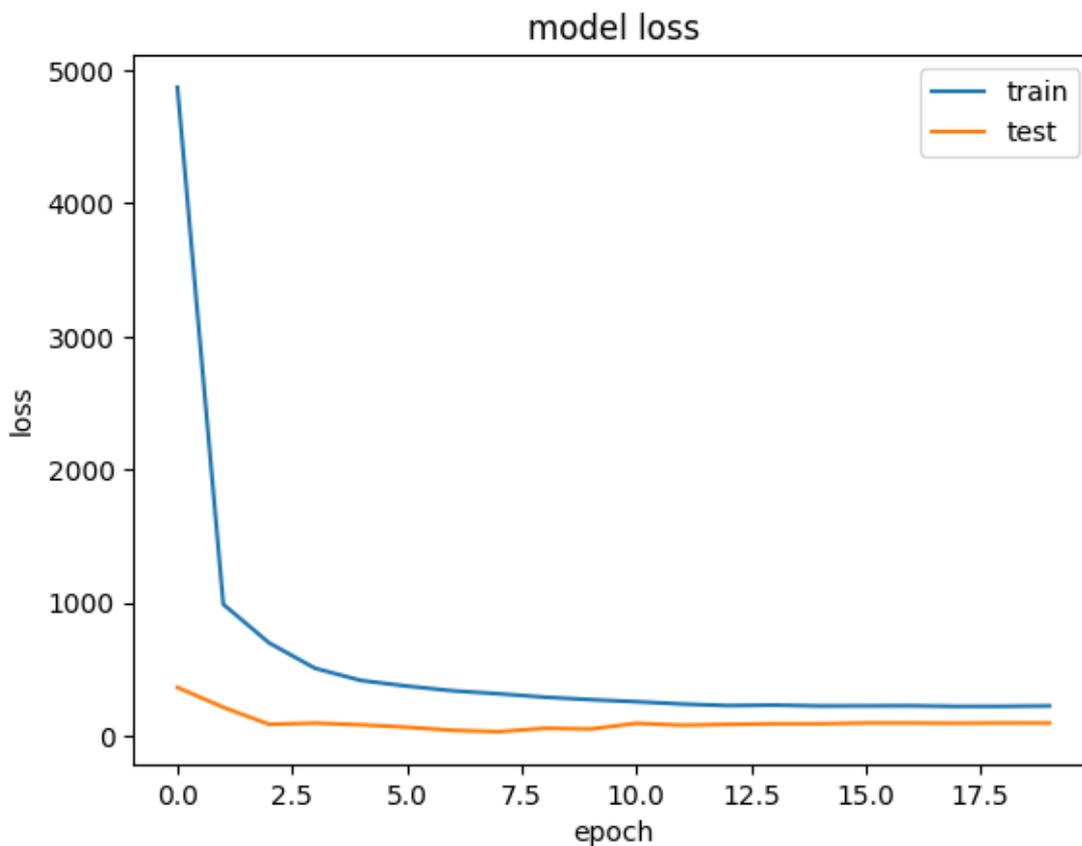


Figure III_9 courbe d'apprentissage RL

Les performances du modèle ont été évaluées à l'aide de la matrice de confusion et du rapport de classification, et ont montré des performances élevées avec une précision globale de 93,45% et un score F1 de 99,05%. Ces résultats indiquent que le modèle est capable de bien classifier les données. Ces résultats suggèrent que le modèle de maintenance prédictive est bien entraîné, capable de détecter les défaillances de manière précise tout en minimisant les faux positifs et les faux négatifs.

III.5.2 Paramètres d'évaluation de ANN

Tableau III_2 précisions, Recall et score F1 en utilisant le modèle ANN

Classes	Précision	Recall	F1_score
0	0,9997	0.91	0.939
1	0.9993	0.9998	0.9995

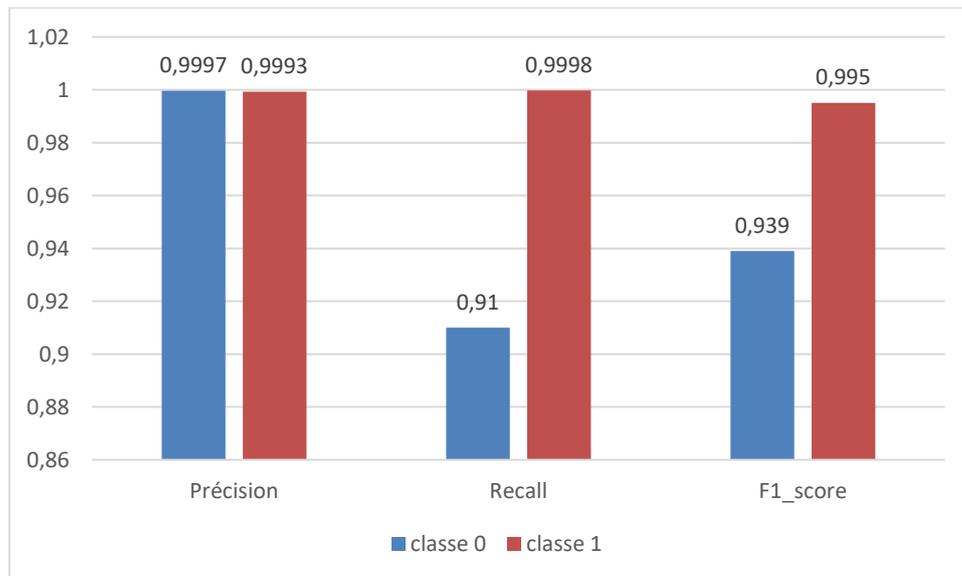


Figure III_10 Scores de Précision, Rappel et F1 par Classe

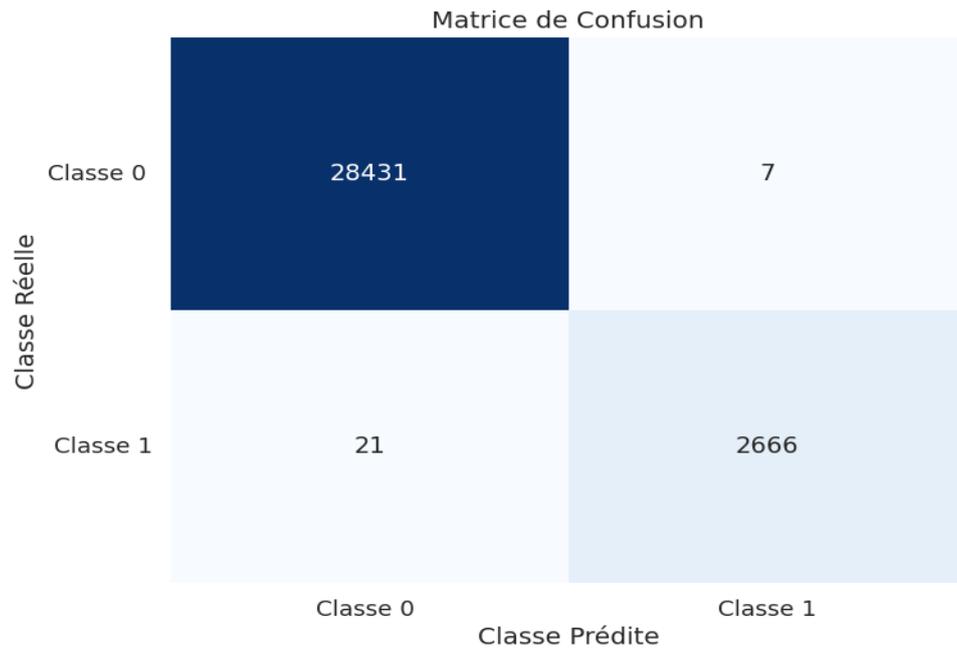


Figure III_11 Matrice de confusion pour ANN

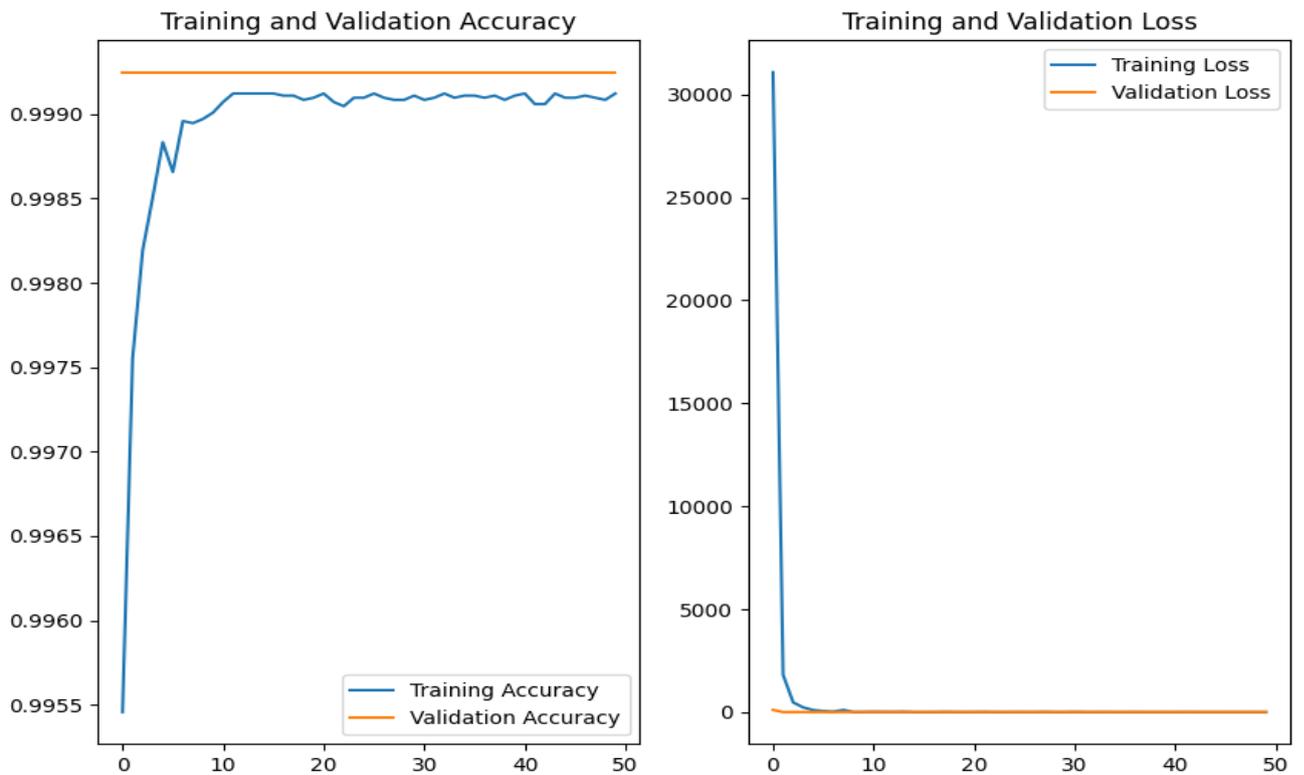


Figure III_12 courbes d'apprentissage pour ANN

D'après les résultats obtenus, la classification pour prédire les défaillances imminentes dans notre système de maintenance prédictive est très précise. En effet, le modèle présente une précision de 99,99% pour la détection des défaillances et une précision de 99,3% pour la détection de l'absence de défaillances, avec une précision globale de 99,9%. Le rappel est également élevé pour les deux classes, ce qui indique que le modèle est capable d'identifier correctement les défaillances et de les distinguer des cas sans défaillance. La matrice de confusion montre également un nombre très faible de faux positifs et de faux négatifs. Enfin, le graphique de l'historique d'apprentissage montre une baisse régulière de la perte et une amélioration continue de la précision du modèle, ce qui indique que le modèle a été correctement entraîné.

En résumé, le modèle ANN performe mieux que le modèle de régression logistique dans toutes les métriques évaluées

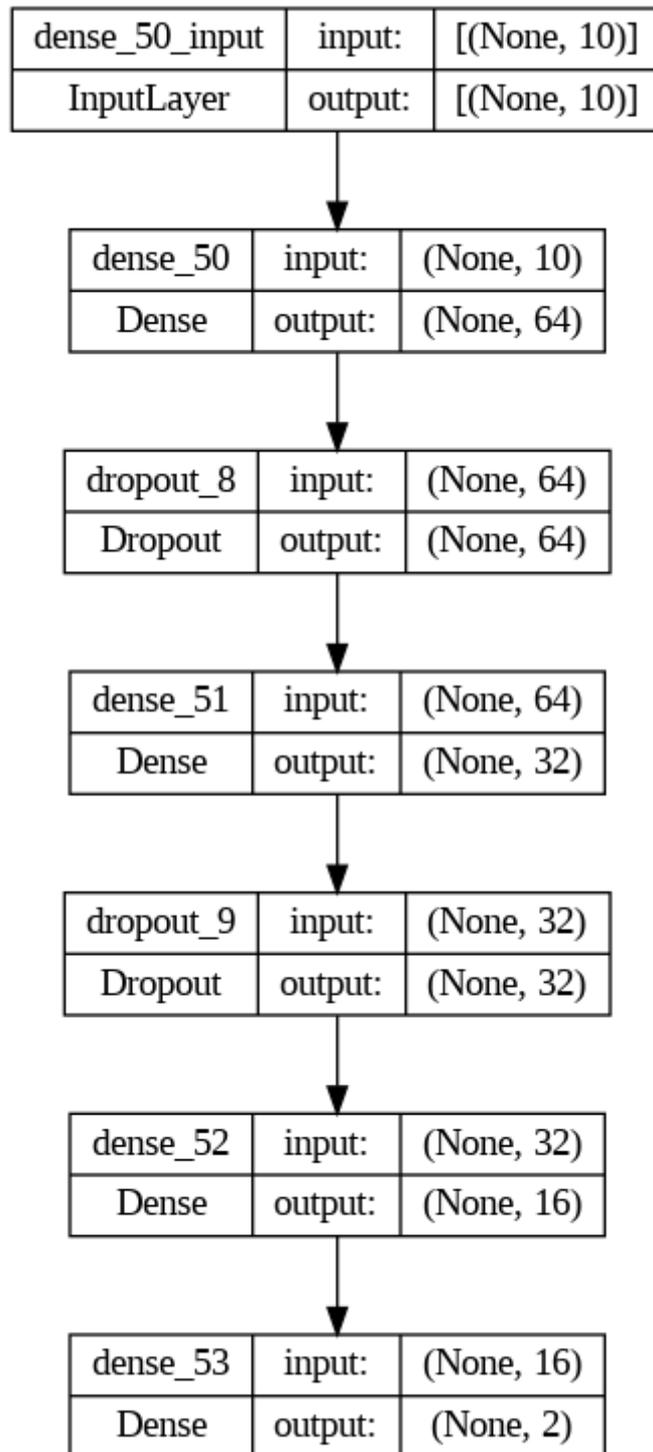


Figure III_13 Architecture de ANN

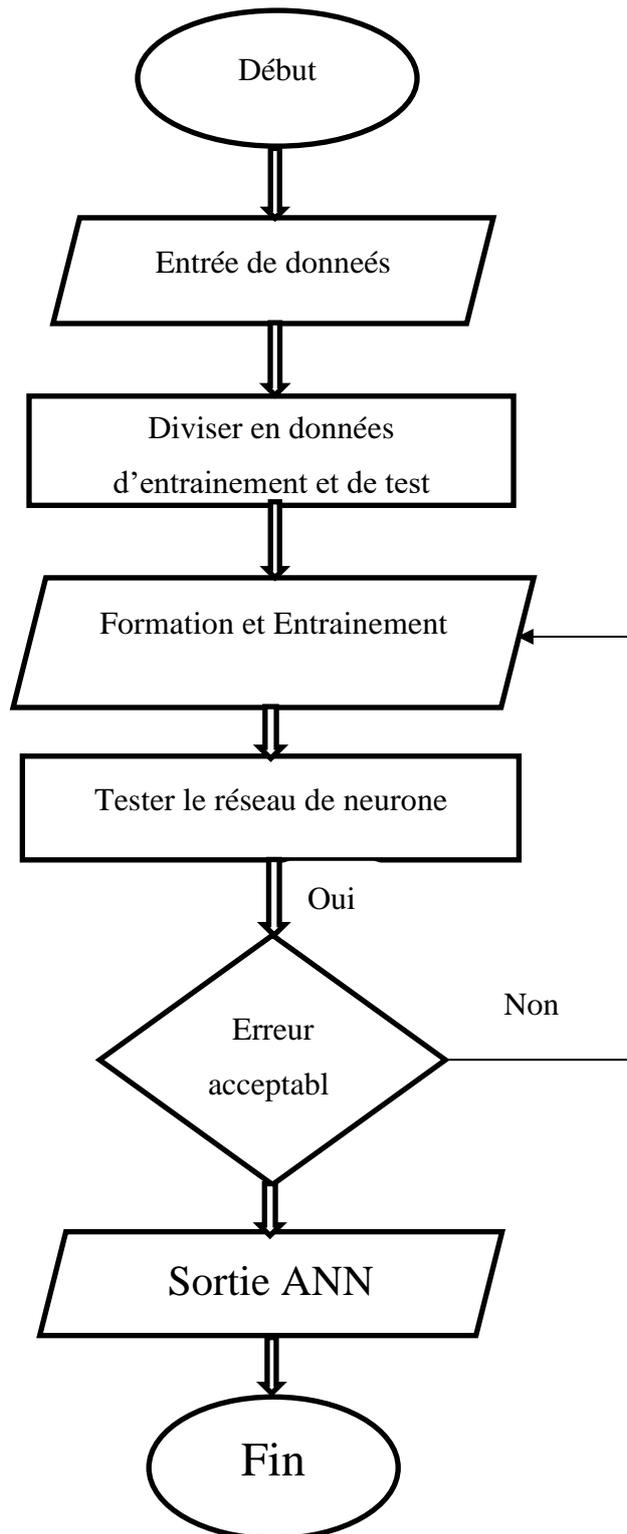


Figure III.14 L'organigramme de fonctionnement de ANN

III.6 Conclusion

Dans ce chapitre, nous avons présenté la mise en œuvre de notre méthode basée sur l'apprentissage automatique, ainsi que les résultats de nos simulations. Nous avons utilisé Google Colab comme environnement de développement, idéal pour exécuter du code Python et traiter nos données de capteurs. Notre étude s'est appuyée sur un vaste ensemble de données comprenant des mesures comme la température et la vibration, essentielles pour entraîner nos modèles. Les évaluations ont montré que nos modèles, tels que la régression logistique et les réseaux de neurones, sont capables de détecter avec précision les défaillances des appareils, avec des scores élevés de précision et de rappel. Ces résultats indiquent que notre approche peut contribuer significativement à la maintenance prédictive en identifiant les problèmes potentiels avant qu'ils ne deviennent critiques.

CONCLUSION GÉNÉRALE

CONCLUSION GÉNÉRALE

CONCLUSION GÉNÉRALE

Ce mémoire a exploré de manière exhaustive le développement et la mise en œuvre d'un système de maintenance prédictive basé sur les technologies de l'Internet des objets (IoT) et de l'apprentissage automatique. La maintenance prédictive se révèle être une stratégie avancée essentielle pour anticiper les pannes des équipements, ce qui permet de réduire les coûts de maintenance, d'augmenter la durée de vie des machines et d'assurer une efficacité opérationnelle optimale, particulièrement dans les industries où la fiabilité des équipements est cruciale.

Tout au long de ce travail, nous avons examiné les divers aspects et défis techniques associés à la mise en place d'un tel système. La collecte et l'analyse en temps réel des données provenant de multiples capteurs IoT posent des défis significatifs en termes de gestion et de traitement de grandes quantités de données. Les algorithmes d'apprentissage automatique, tels que la régression logistique et les réseaux de neurones artificiels (ANN), jouent un rôle clé dans l'analyse de ces données et dans l'identification des schémas précurseurs de pannes imminentes. Ces technologies permettent une surveillance continue de l'état des équipements et facilitent une intervention proactive.

Notre projet de fin d'études s'est concentré sur la conception et le développement théorique d'un système de maintenance prédictive intégrant plusieurs technologies de détection. En adoptant une approche multi-technologique, nous avons pris en compte la diversité des environnements industriels et des types d'équipements. Cette intégration de différentes technologies nous a permis d'augmenter les chances de détection et de prévision des pannes, quels que soient les environnements industriels. Elle a également permis de tirer parti des progrès technologiques réalisés dans chaque domaine et d'améliorer la performance globale de notre solution.

L'organisation de ce mémoire en trois chapitres a permis de structurer et de présenter nos recherches et analyses de manière claire et concise :

- **Chapitre 1** : Nous avons mis en évidence le contexte technologique et les défis associés à la maintenance industrielle, en soulignant l'importance et les bénéfices de la maintenance prédictive dans divers secteurs industriels. Nous avons exploré plusieurs approches basées sur l'IoT et l'apprentissage automatique pour la surveillance et la prédiction des pannes.

CONCLUSION GÉNÉRALE

- **Chapitre 2** : Nous avons détaillé les algorithmes d'apprentissage automatique, notamment la régression logistique et les réseaux de neurones artificiels (ANN), en expliquant leur fonctionnement et en les appliquant à la détection des anomalies.
- **Chapitre 3** : Nous avons discuté de l'extraction des paramètres et de l'utilisation de l'environnement de développement "Google Colab" pour les simulations. Nous avons présenté les résultats de ces simulations et expliqué le principe de fonctionnement du système d'acquisition des données, ainsi que le système de détection et de classification des défauts.

Bien que ce travail ait principalement été axé sur des études théoriques et des simulations, les résultats obtenus démontrent l'efficacité potentielle d'un système de maintenance prédictive basé sur l'IoT et l'apprentissage automatique. Cette approche apporte une contribution significative à l'optimisation des processus de maintenance et à la réduction des coûts opérationnels, tout en augmentant la durée de vie et la fiabilité des équipements industriels.

En conclusion, ce mémoire ouvre la voie à de futures recherches et développements pratiques, notamment en intégrant de nouvelles technologies de détection et d'analyse, et en appliquant ces méthodes dans des environnements industriels diversifiés. La maintenance prédictive, grâce à l'IoT et à l'apprentissage automatique, est une approche incontournable pour garantir la fiabilité et la durabilité des équipements dans un monde industriel de plus en plus connecté et automatisé.

CONCLUSION GÉNÉRALE

PERSPECTIVES :

Comme perspectives, nous proposerons les travaux suivants :

- 1 Réalisation Pratique du Système :
 - **Prototypage et Mise en Œuvre** : La prochaine étape logique serait de réaliser un prototype fonctionnel du système de maintenance prédictive, intégrant les capteurs IoT, les dispositifs de communication et les algorithmes d'apprentissage automatique. Cela permettra de valider les résultats théoriques et de tester la performance du système dans des conditions réelles.
 - **Tests en Conditions Réelles** : Une fois le prototype réalisé, il serait crucial de le tester dans divers environnements industriels pour évaluer sa robustesse, sa précision et sa fiabilité en situation réelle.
- 2 Améliorer les performances
- 3 Abaisser le temps d'exécution en embarquant les solutions réalisées sur un circuit hardware (FPGA, DSP) afin de satisfaire la contrainte temps réel

Références

- [1]. <https://dusuniot.com/fr/blog/what-is-iot-predictive-maintenance/>
- [2]. <https://www.sciencedirect.com/science/article/pii/S0004370279900080>
- [3]. <https://www.cairn.info/revue-outrre-terre2-2016-1-page-62.htm> [Google scholar]
- [4]. J. Benesty, J. Chen, and Y. Huang, "A generalized mvdr spectrum," IEEE Signal Processing Letters, vol. 12, no. 12, pp. 827–830, 2005.
- [5]. A. P. Vela, M. Ruiz, and L. Velasco, "Applying Data Visualization for Failure Localization," in Optical Fiber Communication Conference, OSA Technical Digest (online) (Optical Society of America, 2018), paper W1D.5.
- [6] <https://www.cairn.info/revue-futuribles-2018-3-page-47.htm> [Google Scholar]
- [7] M. A. Khan, H. Menouar, A. Eldeeb, A. Abu-Dayya, and F. D. Salim, "On the detection of unauthorized drones-techniques and future perspectives : A review," IEEE Sensors Journal, 2022.
- [8] <https://slate.com/technology/2019/03/artificial-intelligence-corporate-board-algorithm.html> Éditions Yvon Blais, 2019, p. 83 ; W. PUGH
- [9].<https://fr.mathworks.com/discovery/machine-learning.html>(l'apprentissage automatique/ l'apprentissage non supervisé)
- [10]. [https://www.educba.com/machine-learning-methods/\(méthodes\(d'apprentissage automatique\)\)](https://www.educba.com/machine-learning-methods/(méthodes(d'apprentissage automatique)))
- [11]. <https://rancholabs.medium.com/supervised-learning-algorithm-b5d109f89e8d> (l'apprentissage supervisé)
- [12]. <https://experiences.microsoft.fr/articles/intelligence-artificielle/apprentissage-supervise-et-non-supervise-quelles-differences/> (classification/ régression)
- [13]. <https://machinelearningmastery.com/types-of-classification-in-machinelearning/?fbclid=IwAR3pV1JR4GbAqKSJ7PxoSolDLVvYfC7PyZ2110mKH3ezrWUYp7MHDAeRbR4> (classification)
- [14][https://datatab.fr/tutorial/logistic-regression\(régression logistique\)](https://datatab.fr/tutorial/logistic-regression(régression logistique))
- [15] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," The bulletin of mathematical biophysics, vol. 5, no. 4, pp. 115–133, 1943.
- [16] [Online]. Available : <https://blog.sinatechnologie.com/presentation-des-reseaux-de-neurones-artificiels>
- [17]. <https://www.ibm.com/blogs/internet-of-things/what-is-the-iot/> (L'internet des objets)
- [18]. <https://solace.com/blog/iot-needs-messaging/> (L'internet des objets)

CONCLUSION GÉNÉRALE

- [19]. DAVE, Evans. L'Internet des objets Comment l'évolution actuelle d'Internet transforme-t-elle le monde ? Avril 2011, 12 p
- [20]. <https://research.google.com/colaboratory/faq.html> (Google Colab)
- [22] I. Kakouche and A. Moudoud, "Localisation des sources acoustiques par le système pulse labshop," Département génie électrique, l'école militaire polytechnique, pp. 53– 58, 2017.
- [23] A. Mishra, "Metrics to evaluate your machine learning algorithm (2018)," URL <https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>, 202
- [21]. <https://rancholabs.medium.com/supervised-learning-algorithm-b5d109f89e8d> (l'apprentissage supervisé)
- [22]. <https://experiences.microsoft.fr/articles/intelligence-artificielle/apprentissagesupervise-et-non-supervise-quelles-differences/> (classification/ régression)
- [23] <https://machinelearningmastery.com/typesof-classification-classification,machinelearning/?fbclid=IwAR3pV1JR4GbAqKSJ7PxoSolDLVvYfC7PyZ2110mKH3ezrWU Yp7MHDAeRbR4> (c
- [24]. <https://research.google.com/colaboratory/faq.html> (Google Colab)
- [25]
- [26] https://books.google.fr/books?hl=fr&lr=&id=KUjaWG_V2EC&oi=fnd&pg=PA1&dq=python&ots=ZTM8MdRhHe&sig=2KgKXGvEQU5LBf9oR_bkOa3XmQ [Google Scholar]
- [27] pandas - Python Data Analysis Library, <https://pandas.pydata.org/about/citing.html>
- [28] l'API de Deep Learning, 18 Juin 2021, https://datascientest.com/keras_tous_savoir_sur_keras
- [29] <https://icon-icons.com/icon/tensorflow-logo/170598>